

**MODEL FUNGSI TRANSFER MULTIVARIAT DAN APLIKASINYA
UNTUK MERAMALKAN CURAH HUJAN
DI KOTA YOGYAKARTA**

SKRIPSI

Diajukan kepada Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Negeri Yogyakarta untuk memenuhi sebagian persyaratan
guna memperoleh gelar Sarjana Sains



**Disusun Oleh :
Khrisna Yuli Siswanti
NIM. 07305144019**

**PROGRAM STUDI MATEMATIKA
JURUSAN PENDIDIKAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS NEGERI YOGYAKARTA
2011**

PERSETUJUAN

MODEL FUNGSI TRANSFER MULTIVARIAT DAN APLIKASINYA
UNTUK MERAMALKAN CURAH HUJAN
DI KOTA YOGYAKARTA

Oleh :

Khrisna Yuli Siswanti

07305144019

Telah disetujui pada tanggal 28 Maret 2011
untuk dipertahankan didepan dewan penguji skripsi

Program Studi Matematika
Jurusan Pendidikan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Negeri Yogyakarta

Menyetujui,
PembimbingDr. Dhoriva Urwatul Wutsqa
NIP.19660331 199303 2 001


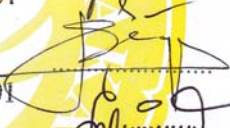

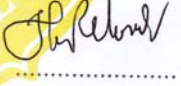
PENGESAHAN

MODEL FUNGSI TRANSFER MULTIVARIAT DAN APLIKASINYA UNTUK MERAMALKAN CURAH HUJAN DI KOTA YOGYAKARTA

Oleh :
Khrisna Yuli Siswanti
07305144019

Telah dipertahankan di depan Tim Penguji Skripsi Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Yogyakarta pada tanggal 7 April 2011 dan dinyatakan telah memenuhi persyaratan guna memperoleh gelar Sarjana Sains.

DEWAN PENGUJI

Jabatan	Nama	Tanda Tangan	Tanggal
Ketua Penguji	Dr. Dhoriva U.W NIP.19660331 199303 2 001		13-04-2011
Sekretaris Penguji	Endang Listyani, M.Si NIP.19591115 198601 2 001		12-04-2011
Penguji Utama	Elly Arliani, M.Si NIP.19670816 199203 2 001		13-04-2011
Penguji Pendamping	Dr. Heri Retnowati NIP.19730103 200003 2 001		13-04-2011

Yogyakarta, April 2011
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Negeri Yogyakarta
Dekan,


Dr. Ariswan
NIP.19590914 198803 1 003



HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini, saya:

Nama : Khrisna Yuli Siswanti

NIM : 07305144019

Program studi : Matematika

Fakultas : FMIPA Universitas Negeri Yogyakarta

Judul TAS : Model Fungsi Transfer Multivariat dan Aplikasinya untuk
Meramalkan Curah Hujan di Kota Yogyakarta

menyatakan bahwa karya ini adalah hasil pekerjaan saya sendiri dan sepanjang sepengetahuan saya, tidak berisi materi yang dipublikasikan atau ditulis oleh orang lain atau telah digunakan sebagai prasyarat penyelesaian studi di perguruan tinggi lain, kecuali pada bagian-bagian yang saya ambil sebagai acuan. Apabila terbukti pernyataan saya ini tidak benar, sepenuhnya menjadi tanggung jawab saya.

Yogyakarta, April 2011

Yang menyatakan,

Khrisna Yuli Siswanti

NIM. 07305144019

MOTTO DAN PERSEMBAHAN

Alhamdulillah.. akhirnya selesai juga..

Terimakasih ya Allah Engkaulah yang membuat aku sabar menjalani semua ini..

"Di balik kesulitan pasti ada jalan keluarnya karena aku yakin Allah tidak akan memberikan cobaan yang melampaui kemampuan umatnya."

"Keyakinan dan kesabaran membuatku percaya bahwa semua persoalan dapat diatasi."

"Tetap semangat dan teruslah berjuang karena hidup adalah perjuangan"

Karya ini kupersembahkan untuk
kalian semua yang selalu mendukungku..

Terimakasih kepada

Bapak dan Ibu, terimakasih telah membesarkanku dengan penuh kasih sayangmu serta memenuhi kebutuhanku selama ini, kini saatnya aku meringankan bebanmu.

Buat Kakakku, dari kecil hingga detik ini kita dibesarkan bersama thanks kau selalu ada untukku dalam suka dan duka.

Buat Seseorang, thanks kau telah membuat hidupku menjadi lebih berwarna.

Teman-teman seperjuangan Mat Swa07, semangat teman!!! Perjalanan kita masih panjang..

**MODEL FUNGSI TRANSFER MULTIVARIAT DAN APLIKASINYA
UNTUK MERAMALKAN CURAH HUJAN
DI KOTA YOGYAKARTA**

Oleh :
Khrisna Yuli Siswanti
NIM. 07305144019

ABSTRAK

Model fungsi transfer merupakan gabungan dari karakteristik analisis regresi berganda dengan karakteristik deret berkala *ARIMA* (*Autoregressive Integrated Moving Average*), sedangkan model fungsi transfer multivariat merupakan model fungsi transfer yang variabel inputnya lebih dari dua deret berkala. Model ini dapat digunakan untuk mendapatkan penentuan ramalan ke depan secara simultan. Di dalam penulisan ini dipaparkan prosedur pembentukan model fungsi transfer multivariat dan aplikasinya untuk meramalkan banyak curah hujan.

Prosedur untuk menentukan model fungsi transfer multivariat diawali dengan pembentukan model *ARIMA* pada masing-masing variabel inputnya. Berdasarkan model *ARIMA* yang terbentuk dilakukan pemutihan deret output dan input kemudian perhitungan korelasi silang antara deret input dan output yang telah diputihkan, yang hasilnya digunakan untuk menentukan order-order fungsi transfer yakni nilai r, s, b dan menghitung nilai bobot respon impuls. Bobot respon impuls berguna untuk menghasilkan deret *noise*. Setelah didapatkan deret *noise* maka dilakukan pembentukan model *ARIMA* pada deret tersebut. Langkah selanjutnya adalah estimasi parameter dan diagnostik untuk mengetahui kesesuaian model yaitu memenuhi asumsi *white noise* dan parameter layak digunakan. Oleh karena pembentukan model fungsi transfer input tunggal telah didapat, tahap selanjutnya adalah melakukan korelasi silang serentak terhadap seluruh variabel input dengan outputnya dan mengestimasi secara serentak seluruh nilai r, s, b yang telah didapat sebelumnya. Apabila ada variabel input yang berkorelasi dengan variabel input lainnya maka salah satu variabel input pasti tidak signifikan, sehingga variabel tersebut dikeluarkan dari model. Terakhir, dilakukan estimasi parameter model fungsi transfer dan diagnostik model.

Penerapan model fungsi transfer multivariat dilakukan untuk meramalkan curah hujan tahun 2010 dan 2011 di Kota Yogyakarta. Data yang digunakan mulai dari tahun 2002 sampai 2009 dengan variabel input kelembaban udara, tekanan udara, temperatur dan kecepatan angin. Oleh karena variabel kelembaban udara menghasilkan *p-value* kelembaban udara yang tidak signifikan maka kelembaban udara harus dikeluarkan dari model. Berikut merupakan model fungsi transfer multivariat hasil peramalan.

$$Y_t = -0,88Y_{t-12} + Y_{t-12} + 0,88Y_{t-24} - 43,229(X_2)_t - 38,04(X_2)_{t-12} + 43,229(X_2)_{t-12} \\ + 38,04(X_2)_{t-24} - 10,39(X_3)_{t-4} - 9,14(X_3)_{t-16} + 10,39(X_3)_{t-16} + 9,14(X_3)_{t-28} \\ - 13,63(X_4)_{t-12} - 11,99(X_4)_{t-24} + 13,63(X_4)_{t-24} + 11,99(X_4)_{t-36} + a_{t-1} + 0,349a_{t-1}$$

Berdasarkan model fungsi transfer yang didapat hasil ramalan curah hujan menunjukan terjadinya penurunan curah hujan pada tahun 2010 dan peningkatan curah hujan pada tahun 2011. Curah hujan maksimum pada tahun 2010 adalah 218,88mm pada bulan Maret, sedangkan pada tahun 2011 adalah 458,59mm pada bulan April, minimum untuk kedua tahun terjadi pada bulan Juli yaitu 0,37mm untuk tahun 2010 dan 11,69mm pada tahun 2011. Rata-rata curah hujan pada tahun 2010 adalah 70,88mm dan pada tahun 2011 adalah 175,58mm.

KATA PENGANTAR

Syukur Alhamdulillah senantiasa penulis panjatkan ke hadirat Allah SWT yang telah memberikan rahmat dan karunia-Nya sehingga skripsi yang berjudul “Model Fungsi Transfer Multivariat dan Aplikasinya untuk Meramalkan Curah Hujan di Kota Yogyakarta” dapat terselesaikan.

Penulis menyadari bahwa keberhasilan penulisan skripsi ini tidak terlepas dari bantuan berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Ariswan sebagai Dekan FMIPA Universitas Negeri Yogyakarta yang telah memberikan kesempatan penulis dalam menyelesaikan studi.
2. Bapak Dr. Hartono sebagai Ketua Jurusan Pendidikan Matematika Universitas Negeri Yogyakarta yang telah memberikan kelancaran dalam pengurusan administrasi selama penyusunan skripsi.
3. Ibu Atmini Dhoruri M.S. sebagai Ketua Program Studi Matematika Universitas Negeri Yogyakarta yang telah memberikan dukungan untuk kelancaran studi.
4. Ibu Dr. Dhoriva U.W. sebagai dosen pembimbing yang telah memberikan banyak bimbingan, masukan, saran serta motivasi selama penyusunan skripsi.
5. Ibu Elly Arliani, M.Si, Ibu Dr. Heri Retnowati dan Ibu Endang Listyani, M.Si. sebagai dosen penguji yang telah memberikan masukan dalam penulisan skripsi ini.
6. Bapak Musthofa S.Si. sebagai dosen Penasehat Akademik yang telah memberikan masukan serta motivasi selama studi.
7. Seluruh dosen Jurusan Pendidikan Matematika FMIPA Universitas Negeri Yogyakarta yang telah memberikan ilmu kepada penulis.

8. Segenap keluarga atas doa dan dukungannya.
9. Teman-teman Matematika Swa 2007 untuk semua saran dan kritiknya kepada penulis.
10. Semua pihak yang telah membantu penulis dalam menyelesaikan skripsi ini.

Penulis menyadari bahwa skripsi ini masih terdapat kekurangan baik isi maupun penyusunannya. Oleh karena itu, penulis mengharapkan saran dan kritik yang membangun untuk perbaikan skripsi ini. Semoga skripsi ini dapat bermanfaat bagi kita semua. Amin.

Yogyakarta, Maret 2011

Penulis

Khrisna Yuli Siswanti

NIM. 07305144019

DAFTAR ISI

HALAMAN JUDUL -----	i
HALAMAN PERSETUJUAN -----	ii
HALAMAN PENGESAHAN-----	iii
HALAMAN PERNYATAAN -----	iv
HALAMAN MOTTO & PERSEMBAHAN -----	v
ABSTRAK-----	vi
KATA PENGANTAR -----	vii
DAFTAR ISI -----	ix
DAFTAR TABEL -----	xi
DAFTAR GAMBAR -----	xiii
DAFTAR LAMPIRAN -----	xv
 BAB I PENDAHULUAN	
A. Latar Belakang Masalah -----	1
B. Rumusan Masalah -----	3
C. Tujuan Penulisan-----	4
D. Manfaat Penulisan-----	4
 BAB II LANDASAN TEORI	
A. Pengertian Curah Hujan-----	5
B. Faktor-faktor yang Mempengaruhi Curah Hujan -----	6
C. Pengertian Peramalan-----	8
D. Pengertian Data Deret Berkala -----	9
E. <i>ACF (Autocorrelation Function)</i> -----	10

F. <i>PACF (Partial Autocorrelation Function)</i> -----	13
G. <i>Proses White Noise</i> -----	14
H. <i>Stasioneritas</i> -----	16
I. <i>Autoregressive Integrated Moving Average (ARIMA)</i> -----	21
J. <i>Langkah-langkah Pemodelan ARIMA</i> -----	31
K. <i>Seasonal Autoregressive Integrated Moving Average (SARIMA)</i> -----	34

BAB III PEMBAHASAN

A. <i>Model Fungsi Transfer</i> -----	37
B. <i>Prosedur Menentukan Model Fungsi Transfer Multivariat</i> -----	40
C. <i>Penerapan Model Fungsi Transfer Multivariat</i> -----	52

BAB IV KESIMPULAN DAN SARAN

A. <i>Kesimpulan</i> -----	105
B. <i>Saran</i> -----	109

DAFTAR PUSTAKA -----	110
-----------------------------	-----

LAMPIRAN -----	111
-----------------------	-----

DAFTAR TABEL

Tabel 2.1 Transformasi Box-Cox.....	21
Tabel 3.1. Model Fungsi Transfer dengan $r = 0$	45
Tabel 3.2 Model Fungsi Transfer dengan $r = 1$	45
Tabel 3.3 Model Fungsi Transfer dengan $r = 2$	46
Tabel 3.4 Estimasi Parameter, Uji Signifikansi dan Nilai <i>AIC</i> Model <i>ARIMA</i> untuk Input Kelembaban Udara.	63
Tabel 3.5 <i>Autocorrelation Check of Residuals</i> Model	
$ARIMA(2,0,0)(0,1,1)^{12}$ untuk Input Kelembaban Udara.....	65
Tabel 3.6 Estimasi Parameter, Uji Signifikansi dan Nilai <i>AIC</i> Model <i>ARIMA</i> untuk Input Tekanan Udara.....	65
Tabel 3.7 <i>Autocorrelation Check of Residuals</i> Model	
$ARIMA(1,0,1)(0,1,1)^{12}$ untuk Input Tekanan Udara	67
Tabel 3.8 Estimasi Parameter dan Uji Signifikansi Model $ARIMA(0,0,2)(2,1,0)^{12}$ untuk Input Temperatur.	68
Tabel 3.9 <i>Autocorrelation Check of Residuals</i> Model	
$ARIMA(0,0,2)(2,1,0)^{12}$ untuk Input Temperatur.	69
Tabel 3.10 Estimasi Parameter dan Uji Signifikansi Model	
$ARIMA(1,0,0)(0,1,1)^{12}$ untuk Input Kecepatan Angin.	70
Tabel 3.11 <i>Autocorrelation Check of Residuals</i> Model	

<i>ARIMA(1,0,0) (0,1,1)</i> ¹² untuk Kecepatan Angin.....	71
Tabel 3.12 Diskripsi Statistik pada Korelasi Silang Masing-masing Deret Input dan Output	
Tabel 3.13 Bobot Respon Impuls yang Mengidentifikasi	
Fungsi Transfer	81
Tabel 3.14 Estimasi penentuan (r,s,b)	82
Tabel 3.15 Estimasi Parameter Masing-masing Deret <i>Noise</i>	87
Tabel 3.16 Uji <i>Ljung-Box</i> Masing-masing Deret <i>Noise</i>	88
Tabel 3.17 Estimasi Parameter Variabel Input Model Fungsi Transfer.....	90
Tabel 3.18 <i>Autocorrelation Check of Residuals</i> pada	
Masing-masing Model Fungsi Transfer	92
Tabel 3.19 <i>Crosscorrelation Check of Residuals</i> pada	
Masing-masing Model Fungsi Transfer	94
Tabel 3.20 Estimasi Parameter Fungsi Transfer Multivariat.....	98
Tabel 3.21 Estimasi Parameter Akhir Fungsi Transfer Multivariat	99
Tabel 3.22 <i>Autocorrelation Check of Residuals</i> pada	
Model Fungsi Transfer Multivariat	101
Tabel 3.23 <i>Crosscorrelation Check of Residuals</i> pada	
Model Fungsi Transfer Multivariat	102
Tabel 3.24 Hasil Ramalan Curah Hujan dengan Model	
Transfer Multivariat.....	103

DAFTAR GAMBAR

Gambar 2.1 Plot <i>ACF</i> Variabel Input Temperatur	12
Gambar 2.2. Plot <i>Time series</i> dan Autokorelasi Data	
Stasioner dalam Rata-rata	17
Gambar 2.3. Plot <i>Time series</i> dan Autokorelasi Data	
Tidak Stasioner dalam Rata-rata	17
Gambar 2.4. Plot <i>Time series</i> dan Autokorelasi Data Stasioner	
dalam Varians	20
Gambar 2.5. Plot <i>Time series</i> dan Autokorelasi Data Belum Stasioner dalam Varians	
Gambar 2.6 Plot <i>ACF</i> dan <i>PACF</i> Model <i>AR</i> (1).....	23
Gambar 2.7 Plot <i>ACF</i> dan <i>PACF</i> Model <i>AR</i> (2).....	24
Gambar 2.8 Plot <i>ACF</i> dan <i>PACF</i> Model <i>MA</i> (1)	26
Gambar 2.9 Plot <i>ACF</i> dan <i>PACF</i> Model <i>MA</i> (2)	27
Gambar 2.10 Plot <i>ACF</i> dan <i>PACF</i> Model <i>ARMA</i> (1,1)	29
Gambar 2.11 Plot <i>Time series</i> dan <i>ACF</i> Pola Musiman	34
Gambar 2.12 Diagram Alir Langkah-langkah Pemodelan <i>ARIMA</i>	36
Gambar 3.1 Konsep Fungsi Transfer	37
Gambar 3.2 Plot <i>Time Series</i> Data Curah Hujan.....	52
Gambar 3.3 Plot <i>ACF</i> dan <i>PACF</i> Data Curah Hujan Menunjukkan	
Data Belum Stasioner dalam Rata-rata dan Varians	53

Gambar 3.4 Plot <i>ACF</i> dan <i>PACF</i> Data Curah Hujan Setelah Dilakukan Pembedaan Duabelas ($d = 12$)	54
Gambar 3.5 Plot <i>Time Series</i> Data Kelembaban Udara.....	54
Gambar 3.6 Plot <i>ACF</i> dan <i>PACF</i> Data Kelembaban Udara Menunjukkan Data Belum Stasioner dalam Rata-rata dan Varians.....	55
Gambar 3.7 Plot <i>ACF</i> dan <i>PACF</i> Data Kelembaban Udara Setelah Dilakukan Pembeda Dua Belas ($d = 12$)	55
Gambar 3.8 Plot <i>Time Series</i> Data Tekanan Udara	56
Gambar 3.9 Plot <i>ACF</i> dan <i>PACF</i> Data Tekanan Udara Menunjukkan Data Belum Stasioner dalam Rata-rata dan Varians.....	57
Gambar 3.10 Plot <i>ACF</i> dan <i>PACF</i> Data Tekanan Udara Setelah Dilakukan Pembedaan Duabelas ($d = 12$)	57
Gambar 3.11 Plot <i>Time Series</i> Data Temperatur	58
Gambar 3.12 Plot <i>ACF</i> dan <i>PACF</i> Data Temperatur Menunjukkan Data Belum Stasioner dalam Rata-rata	59
Gambar 3.13 Plot <i>ACF</i> dan <i>PACF</i> Data Temperatur Setelah Dilakukan Pembeda Duabelas ($d = 12$)	60
Gambar 3.14 Plot <i>Time Series</i> Data Kecepatan Angin	61
Gambar 3.15 Plot <i>ACF</i> dan <i>PACF</i> Data Kecepatan Angin Menunjukkan Data Stasioner dalam Rata-rata	61
Gambar 3.16 Plot <i>ACF</i> dan <i>PACF</i> Data Kecepatan Angin Setelah Dilakukan Pembeda Duabelas ($d = 12$).....	62

Gambar 3.17 Plot <i>ACF</i> masing-masing deret input yang telah diputihkan.....	77
Gambar 3.18 Plot <i>CCF</i> Masing-masing Deret Input dan Output yang Telah Diputihkan.....	79
Gambar 3.19 Plot <i>ACF</i> dan <i>PACF</i> pada Deret <i>Noise</i> Kelembaban Udara	84
Gambar 3.20 Plot <i>ACF</i> dan <i>PACF</i> pada Deret <i>Noise</i> Tekanan Udara.....	84
Gambar 3.21 Plot <i>ACF</i> dan <i>PACF</i> pada Deret <i>Noise</i> Temperatur	85
Gambar 3.22 Plot <i>ACF</i> dan <i>PACF</i> pada Deret <i>Noise</i> Kecepatan Angin	86
Gambar 3.23 Plot <i>Time Series</i> Hasil Ramalan Tahun 2010-2011	104

DAFTAR LAMPIRAN

Lampiran 1 Data Deret Input dan Output.....	111
Lampiran 2 Deret Input dan Output yang Telah Diputihkan	114
Lampiran 3 Plot Korelasi Silang Deret Input dan Output yang Telah Diputihkan	120
Lampiran 4 Deret <i>Noise</i> Masing-masing Variabel Input	124
Lampiran 5 Plot <i>ACF</i> dan <i>PACF</i> Deret <i>Noise</i> Gabungan	126
Lampiran 6 Output Hasil Estimasi Program SAS	128
Lampiran 7 Sintak Program SAS	138
Lampiran 8 Tabel Distribusi <i>Chi-square</i>	141
Lampiran 9 Tabel Distribusi <i>t</i>	142

BAB I

PENDAHULUAN

A. Latar Belakang Masalah

Peramalan merupakan suatu cara untuk memprediksi apa yang akan terjadi di masa yang akan datang. Banyak cara yang dipelajari dalam matematika untuk meramalkan suatu kemungkinan salah satunya adalah dengan menggunakan analisis deret berkala. Analisis deret berkala adalah peramalan yang didasarkan pada data kuantitatif masa lalu dimana hasil ramalan yang dibuat tergantung dengan metode yang digunakan. Tahapan yang harus dilalui dalam perancangan suatu metode peramalan adalah melakukan analisis pada data masa lampau agar mendapatkan gambaran pola dari data yang bersangkutan dengan tujuan memperoleh metode yang paling sesuai, sehingga dengan adanya peramalan tentu saja suatu perencanaan akan lebih efektif dan efisien.

Analisis data deret berkala pada dasarnya digunakan untuk melakukan analisis data yang mempertimbangkan pengaruh waktu. Data-data yang dikumpulkan secara periodik berdasarkan urutan waktu, bisa dalam jam, hari, minggu, bulan, kuartal dan tahun, dapat dilakukan analisis menggunakan metode analisis data deret berkala. Analisis data deret berkala tidak hanya dapat dilakukan untuk satu variabel (univariate) tetapi juga dapat untuk banyak variabel (multivariat). Selain itu pada analisis data deret berkala dapat dilakukan peramalan data beberapa periode ke depan yang sangat membantu dalam menyusun perencanaan ke depan. (Makridakis, dkk:1993)

Model *ARIMA* (*Autoregressive Integrated Moving Average*) merupakan gabungan dari metode penghalusan, metode regresi, dan metode dekomposisi yang digunakan untuk peramalan analisis data deret berkala tunggal atau sering disebut model univariate. Untuk data deret berkala berganda tidak dapat dilakukan analisis menggunakan model *ARIMA*, oleh karena itu diperlukan model-model multivariat. Model-model yang masuk kelompok multivariat analisisnya lebih rumit dibandingkan dengan model-model univariate. Pada model multivariat sendiri bisa dalam bentuk analisis data bivariat (yaitu hanya data dua deret berkala) dan dalam bentuk data multivariat (yaitu data terdiri lebih dari dua deret berkala). Model-model multivariat diantaranya: model fungsi transfer, model analisis intervensi (*intervention analysis*), *fourier analysis*, analisis spectral dan *vector time series models*.

Model fungsi transfer merupakan salah satu model peramalan kuantitatif yang dapat digunakan untuk peramalan data deret berkala yang multivariat. Model ini menggabungkan beberapa karakteristik analisis regresi berganda dengan karakteristik deret berkala *ARIMA*. Konsep fungsi transfer terdiri dari deret input, deret output, dan seluruh pengaruh lain yang disebut dengan gangguan. Model ini dapat digunakan untuk mendapatkan penentuan ramalan kedepan secara simultan

Banyak hal di kehidupan ini yang dapat diramalkan untuk mendapatkan suatu perencanaan yang lebih baik. Kasus dalam bidang kesehatan, pertanian, penjualan juga bidang meteorology dapat dilakukan peramalan guna mengetahui langkah yang harus diambil untuk memperkecil resiko yang tidak diinginkan. Disini penulis mencoba mengkaji lebih dalam tentang peramalan dengan model

fungsi transfer di bidang meteorology dan geofisika khususnya untuk meramalkan curah hujan di Yogyakarta mulai dari Januari 2010 sampai Desember 2011.

Curah hujan dipengaruhi oleh beberapa faktor antara lain kelembaban udara, temperatur, tekanan udara, intensitas sinar matahari, kecepatan angin dan lain-lain. Output yang akan digunakan adalah banyaknya curah hujan sedangkan inputnya adalah beberapa faktor yang mempengaruhi curah hujan yaitu kelembaban udara, temperatur, tekanan udara, dan kecepatan angin. Oleh karena faktor yang diambil sebagai input lebih dari dua maka peramalan ini termasuk dalam peramalan dengan variabel multivariat.

Berdasarkan uraian di atas penulis ingin menguraikan cara pemodelan fungsi transfer multivariat untuk memprediksi banyak curah hujan yang akan terjadi di masa mendatang. Untuk itu penulis mengambil judul “Model Fungsi Transfer Multivariat dan Aplikasinya untuk Meramalkan Curah Hujan di Kota Yogyakarta”.

B. Rumusan Masalah

Berdasarkan latar belakang masalah di atas, maka dirumuskan pokok permasalahan yang akan menjadi kajian skripsi ini adalah sebagai berikut :

1. Bagaimana prosedur untuk menentukan model fungsi transfer multivariat?
2. Bagaimana model peramalan banyak curah hujan di Kota Yogyakarta mulai dari Januari 2010 sampai Desember 2011 dengan fungsi transfer multivariat?

3. Bagaimana hasil ramalan curah hujan mulai dari bulan Januari 2010 sampai Desember 2011 di Kota Yogyakarta?

C. Tujuan Penulisan

Adapun tujuan dari penulisan ini, yaitu:

1. Menjelaskan prosedur untuk menentukan model fungsi transfer multivariat
2. Mendapatkan model peramalan banyak curah hujan dengan fungsi transfer multivariat.
3. Mendeskripsikan ramalan curah hujan mulai dari Januari 2010 sampai Desember 2011 di Kota Yogyakarta.

D. Manfaat Penulisan

Hasil dari peramalan curah hujan dapat digunakan pada bidang pertanian misalnya sebagai pertimbangan dalam menentukan jenis tanaman yang akan ditanam dan prediksi curah hujan juga dapat memperlancar aktivitas masyarakat dalam mempersiapkan diri menghadapi musim hujan. Selain itu dapat juga untuk menambah khasanah ilmu pengetahuan dalam penerapan konsep model fungsi transfer di bidang-bidang yang lain. Selanjutnya, diharapkan dapat memberikan masukan atau informasi yang bermanfaat dalam meramalkan nilai yang akan terjadi di masa mendatang.

BAB II

LANDASAN TEORI

Curah hujan merupakan salah satu hal penting dalam kehidupan ini. Khususnya dalam bidang pertanian sebab curah hujan dapat mempengaruhi hasil pertanian. Oleh karena itu peramalan mengenai curah hujan sangat dibutuhkan untuk membantu proses tanam-menanam. Menurut Wilson(1993:7) faktor yang mempengaruhi banyak curah hujan adalah kelembaban udara, tekanan udara, temperatur dan kecepatan angin yang dapat dicari korelasinya untuk meramalkan curah hujan. Model fungsi transfer multivariat merupakan salah satu model peramalan yang dapat meramalkan kejadian dengan faktor yang digunakan lebih dari dua deret berkala sehingga penulis akan menggunakan fungsi transfer multivariat untuk meramalkan curah hujan.

A. Pengertian Curah Hujan

Curah hujan adalah banyaknya air yang jatuh ke permukaan bumi. Derajat curah hujan dinyatakan dengan jumlah curah hujan dalam suatu satuan waktu. Biasanya satuan yang digunakan adalah mm/jam. Dalam meteorology butiran hujan dengan diameter lebih dari 0.5 mm disebut hujan dan diameter antara 0.5 – 0.1 mm disebut gerimis. Semakin besar ukuran butiran hujan maka semakin besar pula kecepatan jatuhnya. Ketelitian alat ukur curah hujan adalah 1/10 mm. Pembacaan dilakukan satu

kali dalam sehari dan dicatat sebagai curah hujan hari terdahulu/kemarin (Suyono,1985:8).

B. Faktor-faktor yang Mempengaruhi Curah Hujan

1. Kelembaban Udara

Kelembaban adalah perbandingan antara massa uap dalam suatu satuan volum dengan massa uap yang jenuh dalam satuan volum itu pada suhu yang sama. Secara umum kelembaban menyatakan banyaknya kadar air yang ada di udara. Banyaknya uap yang bergerak di dalam atmosfer berpengaruh terhadap besarnya hujan, lamanya hujan, dan intensitas curah hujan. Kelembaban tertinggi umumnya terjadi pada musim penghujan dan paling rendah pada musim kemarau. Variasi kelembaban bergantung dari suhu udara, jika pagi hari suhu rendah maka kelembaban akan lebih tinggi jika dibanding pada siang hari saat suhu tinggi.

Umumnya semakin tinggi suatu daerah dari permukaan laut maka kelembaban udaranya semakin tinggi. Makin tinggi kelembaban udara akan dapat menyebabkan bertambah banyak uap air yang dapat diserap awan. Uap air itu akan menghasilkan tekanan yang dinyatakan dengan satuan tinggi air raksa ($1 \text{ mmHg} = 1,33 \text{ milibar}$). Tekanan yang diberikan oleh uap air disebut dengan tekanan uap air. (Suyono,1985:12)

2. Tekanan Udara

Tekanan udara merupakan tenaga yang bekerja untuk menggerakkan massa udara dalam setiap satuan luas tertentu. Diukur dengan menggunakan barometer. Satuan tekanan udara adalah milibar (mb). Garis yang

menghubungkan tempat-tempat yang sama tekanan udaranya disebut sebagai isobar.

Tekanan udara dibatasi oleh ruang dan waktu. Artinya pada tempat dan waktu yang berbeda, besarnya juga berbeda. Semakin tinggi suatu tempat maka tekanan udaranya semakin menurun, sedangkan tekanan udara pada daerah yang mempunyai rata-rata ketinggian sama maka tekanan udara dipengaruhi oleh suhu udara. Daerah yang suhu udaranya tinggi akan bertekanan rendah dan daerah yang bersuhu udara rendah tekanannya tinggi. (Soewarno,2000:10)

3. Suhu Udara

Suhu udara adalah keadaan panas atau dinginnya udara. Suhu juga disebut temperatur yang diukur dengan alat [termometer](#). Beberapa faktor yang mempengaruhi suhu udara diantaranya: tinggi tempat, daratan/lautan, radiasi matahari, indeks datang matahari dan angin. Pengukuran biasa dinyatakan dalam skala Celsius (C), Reamur (R), dan Fahrenheit (F). Suhu udara tertinggi di permukaan bumi adalah di daerah tropis (sekitar ekuator) dan makin ke kutub makin dingin.(Soewarno,2000:12)

4. Kecepatan Angin

Angin adalah udara yang bergerak akibat adanya perbedaan tekanan udara dengan arah aliran angin dari tempat yang memiliki tekanan tinggi ke tempat yang bertekanan rendah atau dari daerah yang memiliki suhu / temperatur rendah ke wilayah bersuhu tinggi. Angin memiliki hubungan yang erat dengan sinar matahari karena daerah yang terkena banyak paparan sinar matahari akan memiliki suhu yang lebih tinggi serta tekanan udara yang lebih rendah dari

daerah lain di sekitarnya sehingga menyebabkan terjadinya aliran udara. Angin juga dapat disebabkan oleh pergerakan benda sehingga mendorong udara di sekitarnya untuk bergerak ke tempat lain. (Soewarno,2000:15)

C. Pengertian Peramalan

Peramalan adalah penentuan nilai suatu variabel pada masa yang akan datang menggunakan arah dan pola perkembangan data masa lalu. Menurut Assauri(1984:7) peramalan merupakan kegiatan dalam memperkirakan apa yang akan terjadi pada masa yang akan datang. Atau lebih tepatnya peramalan adalah kegiatan mencoba menduga perubahan yang akan terjadi. Sedangkan ramalan adalah situasi/kondisi yang diperkirakan akan terjadi pada masa yang akan datang. Ramalan dapat diperoleh dengan bermacam-macam cara yang dikenal dengan metode peramalan.

Secara ilmiah metode peramalan dapat diklasifikasikan 2 (dua) kelompok yaitu metode kualitatif dan metode kuantitatif. Metode peramalan kualitatif lebih mengandalkan intuisi manusia daripada penggunaan data historis yang dimiliki. Metode ini banyak digunakan dalam banyak pengambilan keputusan sehari-hari. Dalam hal ini ramalan dikatakan baik/tidak bergantung dari banyak hal antara lain pengalaman, perkiraan dan pengetahuan yang didapat.

Metode peramalan kuantitatif merupakan peramalan yang didasarkan pada data-data variabel yang bersangkutan di masa sebelumnya. Metode ini menggunakan analisis statistik dan tanpa intuisi atau penilaian subyektif orang yang melakukan peramalan.

Menurut Makridakis dkk. (1999:8) peramalan dengan menggunakan metode kuantitatif dapat diterapkan apabila terdapat tiga kondisi berikut :

1. Tersedia informasi tentang masa lalu,
2. Informasi tersebut dapat dikuantitatifkan dalam bentuk data numerik,
3. Dapat diasumsikan bahwa beberapa aspek pola masa lalu akan terus berlanjut dimasa mendatang.

D. Pengertian Data Deret Berkala

Suatu deret berkala adalah himpunan observasi yang terkumpul atau hasil observasi yang mengalami peningkatan waktu (Box dan Jenkins,1976:25). Sedangkan data deret berkala adalah serangkaian nilai-nilai variabel yang disusun berdasarkan waktu. Pada analisis data deret berkala ada empat komponen salah satunya adalah variasi musim. Variasi musim merupakan gerakan suatu deret berkala yang diklasifikasikan ke dalam periode kurang dari satu tahun seperti kuartalan, bulanan atau harian, atau gerakan periodik yang berulang. Bambang Kustitunto(1984:87).

Data sebuah deret berkala dapat mempunyai atau tidak variasi musim, oleh karena itu perlu dilakukan identifikasi terlebih dahulu untuk mengetahui apakah deret tersebut mempunyai variasi musim atau tidak sebelum dilakukan perhitungan. Metode yang paling sederhana untuk mengetahui adanya variasi musim adalah dengan melihat pola yang ada pada plot *time series*. Pola variasi musim dapat diklasifikasikan dalam dua bentuk yakni spesifik dan tipikal. Pola spesifik menunjukkan variasi musim dalam periode misalnya kuartalan. Sedangkan pola tipikal menunjukkan rata-rata variasi musim dalam sejumlah periode seperti lima tahunan.

E. ACF (Autocorrelation Function)

Suatu proses (X_t) yang stasioner akan mempunyai nilai rata-rata konstan $E(X_t) = \mu$ dan varian konstan $\text{Var}(X_t) = E(X_t - \mu)^2 = \sigma^2$. Kovarian antara X_t dan X_{t+k} adalah

$$\gamma_k = \text{Cov}(X_t, X_{t+k}) = E(X_t - \mu)(X_{t+k} - \mu) \quad (2.1)$$

Autokorelasi (ACF) merupakan korelasi atau hubungan antar data pengamatan suatu data deret berkala. Menurut Hanke dan Wichern (2005:60) untuk menghitung koefisien autokorelasi lag-k (ρ_k) antara observasi X_t dan X_{t+k} pada populasi adalah

$$\rho_k = \frac{\text{Cov}(X_t, X_{t+k})}{\sqrt{\text{Var}(X_t)}\sqrt{\text{Var}(X_{t+k})}} \quad (2.2)$$

dimana $\text{Var}(X_t) = \text{Var}(X_{t+k}) = \gamma_0$, γ_k dinamakan fungsi autokovarian dan ρ_k dinamakan fungsi autokorelasi (ACF). (Wei, 1990:10)

Dalam praktiknya ρ tidak diketahui dan diperkirakan dengan (r_k) yang merupakan koefisien korelasi pada sampel dengan rumus

$$r_k = \frac{\sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2} \quad (2.3)$$

dimana

r_k : koefisien autokorelasi

x_t : nilai variabel X pada periode t

x_{t+k} : nilai variabel X pada periode t + k

\bar{x} : nilai rata-rata variabel X

Untuk mengetahui apakah koefisien autokorelasi yang diperoleh signifikan atau tidak perlu dilakukan pengujian dengan hipotesis

$H_0 : \rho_k = 0$ (koefisien autokorelasi tidak signifikan)

$H_1 : \rho_k \neq 0$ (koefisien autokorelasi signifikan)

Statistik uji yang digunakan adalah

$$t = \frac{r_k}{SE(r_k)} \quad (2.4)$$

$$SE(r_k) = \sqrt{\frac{1 + 2 \sum_{i=1}^{k-1} r_i^2}{n}} \quad (2.5)$$

dengan, $SE(r_k)$ = standar error untuk autokorelasi pada lag ke-k

r_i = autokorelasi pada lag ke-i


k = selisih waktu

n = banyaknya observasi dalam deret berkala

Kriteria keputusannya H_0 ditolak jika

$$t < -t_{\frac{\alpha}{2}, n-1} \quad \text{atau} \quad t > t_{\frac{\alpha}{2}, n-1} \quad (2.6)$$

Sebagai contoh dapat dilihat gambar plot ACF berikut ini:



Gambar 2.1 Plot ACF Variabel Input Temperatur

dengan Autocorrelation Function

Lag	ACF	T	LBQ
1	0.153874	1.51	2.34
2	0.356430	3.41	15.06
3	-0.063030	-0.54	15.46
4	-0.103941	-0.89	16.57
5	0.031425	0.27	16.67
6	-0.063096	-0.54	17.08

Dari gambar tersebut terlihat bahwa lag kedua keluar dari garis signifikan dengan nilai

$t_{hit} = 3,41$ dan $t_{tab} = t_{\frac{\alpha}{2}, n-1} = t_{0,025, 95} = 1,960$ sehingga $t = 3,41 > t_{\frac{\alpha}{2}, n-1} = 1,960$ maka H_0

ditolak disimpulkan bahwa koefisien autokorelasi pada lag kedua signifikan. Sedangkan

untuk lag 1, 3, 4, 5, 6 nilai $t_{hit} < t_{\frac{\alpha}{2}, n-1}$ maka pada lag tersebut koefisien autokorelasi tidak

signifikan. Alternatif cara untuk mengecek signifikansi suatu autokorelasi adalah

menggunakan interval kepercayaan yang berpusat di nol dengan rumus sebagai berikut

$$0 \pm t_{\alpha/2} \times SE(r_k) \quad (2.7)$$

Autokorelasi signifikan berbeda nyata dari nol jika nilai r_k berada diluar interval kepercayaan.

F. PACF (Partial Autocorrelation Function)

Koefisien autokorelasi parsial digunakan untuk mengukur derajat hubungan antara nilai-nilai sekarang dengan nilai-nilai sebelumnya dengan pengaruh nilai variabel time lag yang lain dianggap konstan. Sedangkan *Partial Autocorrelation* adalah tingkat keeratan hubungan antara variabel X_t dan X_{t+k} setelah hubungan linear dengan variabel $X_{t+1}, X_{t+2}, \dots, X_{t+k-1}$ dihilangkan sehingga fungsi autokorelasi parsial dapat dinyatakan sebagai berikut: (Wei,1990:12)

$$\phi_{kk} = \text{Corr}(X_t, X_{t+k} \mid X_{t+1}, \dots, X_{t+k-1}) \quad (2.8)$$

Autokorelasi parsial diperoleh melalui model regresi dimana variabel dependen X_{t+k} dari proses yang stasioner pada lag k , sehingga variable $X_{t+k-1}, X_{t+k-2}, \dots, X_t$ dapat ditulis sebagai berikut:

$$X_{t+k} = \phi_{k1} X_{t+k-1} + \phi_{k2} X_{t+k-2} + \dots + \phi_{kk} X_{t+1} + \varepsilon_{t+k} \quad (2.9)$$

dimana ϕ_{ki} = parameter regresi ke- i dan ε_{t+k} = residual normal yang tidak berkorelasi dengan X_{t+k-j} untuk $j \geq 1$. Oleh karena itu fungsi autokorelasi didapatkan

$$\rho_j = \phi_{k1} \rho_{j-1} + \phi_{k2} \rho_{j-2} + \dots + \phi_{kk} \rho_{j-k} \quad (2.10)$$

Untuk $j = 1, 2, \dots, k$ sehingga didapat persamaan berikut:

$$\rho_1 = \phi_{k1} \rho_0 + \phi_{k2} \rho_1 + \dots + \phi_{kk} \rho_{k-1}$$

$$\rho_2 = \phi_{k1} \rho_1 + \phi_{k2} \rho_0 + \dots + \phi_{kk} \rho_{k-2}$$

$$\vdots$$

$$\rho_k = \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0$$

dimana $\rho_0 = 1$ dengan menggunakan aturan Cramer's rule pada persamaan diatas,

maka nilai *PACF* dapat dihitung dengan menggunakan persamaan berikut:

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}} \quad (2.11)$$

dimana $\phi_{kj} = \phi_{k-1,j} - \phi_{kk}\phi_{k-1,k-j}$ untuk $j = 1, 2, \dots, k-1$

G. Proses *White Noise*

Data deret berkala dikatakan mengalami proses *white noise* jika autokorelasi antara deret X_t dan X_{t-k} untuk semua lag k mendekati nol, nilai antar lag pada deret tersebut tidak berkorelasi satu sama lain. Menurut Wei (1990:16) suatu proses $\{a_t\}$ disebut suatu proses *white noise* jika $\{a_t\}$ merupakan barisan variabel acak yang tidak berkorelasi dari suatu distribusi dengan rata-rata konstan $E(a_t) = \mu_0$ yang biasa diasumsikan nol, varians konstan $\text{Var}(a_t) = \sigma_a^2$ dan $\gamma_k = \text{Cov}(a_t, a_{t+k}) = 0$ untuk semua $k \neq 0$. Oleh karena itu, suatu proses *white noise* $\{a_t\}$ adalah stasioner dengan fungsi autokovarian

$$\gamma_k = \begin{cases} \sigma_a^2, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.12)$$

fungsi autokorelasi

$$\rho_k = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.13)$$

dan fungsi autokorelasi parsial

$$\phi_{kk} = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} \quad (2.14)$$

Statistik Q Box-Pierce dikembangkan oleh Ljung-Box dan digunakan untuk mengetahui apakah autokorelasi residualnya berbeda nyata dari nol. Untuk mengetahui apakah suatu deret memenuhi proses *white noise* maka dilakukan uji dengan hipotesis

$H_0 : \rho_1 = \dots = \rho_k = 0$ (tidak ada autokorelasi residual)

$H_1 : \exists \rho_i \neq 0$ (ada autokorelasi residual)

menggunakan statistik uji

$$Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k} \quad (2.15)$$

dengan

n = banyaknya observasi dalam deret berkala

k = lag waktu

m = banyaknya lag yang diuji

r_k = koefisien autokorelasi pada period ke- k


Jika autokorelasi dihitung dari proses *white noise* maka statistik uji Q mempunyai distribusi χ^2 dengan derajat bebas m (banyaknya lag yang diuji), sedangkan untuk residual dari model peramalan statistik uji Q mempunyai distribusi χ^2 dengan derajat

bebasnya m dikurangi banyaknya parameter yang diestimasi dalam model. Kriteria keputusan untuk menolak H_0 adalah jika $Q \geq \chi^2_{\alpha, df}$ atau $p\text{-value} \leq \alpha$. (Hanke and Wichern, 1992:66)

H. Stasioneritas


Menurut Makridakis, dkk (1999: 351) stasioneritas mempunyai makna bahwa tidak terdapat pertumbuhan atau penurunan pada data. Dengan kata lain, fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan varians dari fluktuasi tersebut. Plot data deret berkala dapat digunakan untuk mengetahui suatu data telah stasioner atau belum. Demikian juga plot autokorelasi juga dapat memperlihatkan kestasioneritasan suatu data deret berkala.

Data deret berkala dikatakan stasioner dalam rata-rata jika rata-ratanya tidak berubah dari waktu ke waktu atau data bersifat stabil. Untuk melihat apakah suatu data sudah stasioner dalam rata-rata dapat digunakan alat bantu plot *time series* dan *ACF*. Gambar 2.2 berikut menunjukkan bahwa data deret berkala stasioner dalam rata-rata dan gambar 2.3 memperlihatkan bahwa data deret berkala tidak stasioner dalam rata-rata



Gambar 2.2 Plot *Time series* dan Autokorelasi Data Stasioner dalam Rata-rata

Plot *time series* pada gambar 2.2 memperlihatkan tidak adanya perubahan nilai tengah. Walaupun ada beberapa nilai yang menyimpang jauh akan tetapi bila ditarik garis tengahnya rata-rata nilainya berada di sekitar garis tersebut. Selain itu plot *ACF* juga memperkuat adanya kestasioneran dalam rata-rata. Hal itu dapat dilihat setelah lag pertama mengalami penurunan secara eksponensial, setelah lag kedua dan ketiga terlihat bahwa nilai autokorelasi turun sampai nol walaupun pada lag duabelas keluar dari garis signifikan itu menandakan adanya pengaruh musiman didalamnya. Oleh karena itu, dapat dikatakan data telah stasioner dalam rata-rata.



Gambar 2.3 Plot *Time series* dan Autokorelasi Data Tidak Stasioner dalam Rata-rata

Pada gambar 2.3 plot *time series* memperlihatkan adanya perubahan nilai tengah. Data mengalami kenaikan dan penurunan yang menandakan data tidak stasioner dalam rata-rata. Plot *ACF* terlihat adanya pola gelombang sinus yang menandakan adanya perulangan setiap waktu. Oleh karena itu dapat dikatakan data belum stasioner dalam rata-rata.

Apabila suatu data deret berkala tidak stasioner berdasarkan rata-rata maka dapat diatasi dengan melakukan pembeda (*differencing*). *Differencing* merupakan pengurangan data tertentu dengan data sebelumnya. Jika *differencing* ordo satu

masih belum menghasilkan data yang stasioner, maka dapat dilakukan *differencing* ordo kedua, dan seterusnya hingga diperoleh data stasioner.

Menurut Makridakis, dkk (1999: 382) notasi yang sangat bermanfaat dalam metode pembedaan adalah operator *shift* mundur (*backward shift*) yang disimbolkan dengan B dan penggunaannya adalah sebagai berikut:

$$BX_t = X_{t-1} \quad (2.16)$$

Notasi B yang dipasangkan pada X_t mempunyai pengaruh menggeser data satu periode ke belakang, dua penerapan B untuk X_t akan menggeser data tersebut dua periode ke belakang sebagai berikut:

$$B(BX_t) = B^2X_t = X_{t-2} \quad (2.17)$$

Apabila satu deret berkala tidak stasioner maka data tersebut dapat dibuat lebih mendekati stasioner dengan melakukan pembedaan pertama dari deret data dan persamaannya adalah sebagai berikut:

Pembedaan pertama

$$X'_t = X_t - X_{t-1} \quad (2.18)$$

Menggunakan operator shift mundur persamaan (2.13) dapat ditulis kembali menjadi

Pembedaan pertama

$$X'_t = X_t - BX_t = (1 - B)X_t \quad (2.19)$$

Pembedaan pertama dinyatakan oleh $(1 - B)$. Sama halnya apabila pembedaan orde kedua (yaitu pembedaan pertama dari pembedaan pertama sebelumnya) harus dihitung, maka

Pembedaan orde kedua

$$\begin{aligned}
X_t'' &= X_t' - X_{t-1}' \\
&= (X_t - X_{t-1}) - (X_{t-1} - X_{t-2}) \\
&= (X_t - 2X_{t-1} + X_{t-2}) \\
&= (1 - 2B + B^2)X_t \\
&= (1 - B)^2 X_t
\end{aligned} \tag{2.20}$$


Pembedaan orde kedua diberi notasi $(1 - B)^2$

Tujuan menghitung pembedaan adalah untuk mencapai stasioneritas dan secara umum apabila terdapat pembedaan orde ke-d untuk mencapai stasioneritas ditulis sebagai berikut:

Pembedaan orde ke-d


$$X_t^d = (1 - B)^d X_t \tag{2.21}$$

Suatu data deret berkala dikatakan stasioner dalam varians, jika plot deret berkala tidak memperlihatkan adanya perubahan varians yang jelas dari waktu ke waktu (Makridakis, 1999:333). Begitu pula sebaliknya jika data deret berkala menunjukkan terdapat variasi fluktuasi data pada grafik maka data tersebut termasuk dalam deret berkala yang belum stasioner berdasarkan varians. Untuk melihat suatu data stasioner atau belum dalam varians dapat menggunakan plot *time series* dan plot *ACF*. Gambar 2.4 menunjukkan bahwa data deret berkala stasioner dalam varians dan gambar 2.5 menunjukkan bahwa data deret berkala belum stasioner dalam varians.



Gambar 2.4 Plot *Time series* dan Autokorelasi Data Stasioner dalam Varians

Pada gambar 2.4 plot *time series* memperlihatkan bahwa data stasioner dalam varians. Hal itu dikarenakan tidak terlihat adanya perubahan varians yang begitu jelas. Begitu pula dengan plot *ACF* pada setelah lag pertama mengalami penurunan yang cepat sehingga dapat dikatakan data stasioner dalam varians.



Gambar 2.5 Plot *Time series* dan Autokorelasi Data Belum Stasioner dalam Varians

Plot *time series* dan *ACF* pada gambar 2.5 memperlihatkan bahwa data belum stasioner dalam varians. Pola musiman terlihat pada kedua plot tersebut. Data berfluktuasi tajam lalu didukung dengan plot *ACF* yang memperlihatkan adanya pola gelombang sinus yang menandakan adanya perubahan varians. Jadi dapat disimpulkan bahwa data belum stasioner dalam varians.

Untuk menstasionerkan data yang belum stasioner dalam varians dapat dilakukan dengan proses transformasi. Secara umum, untuk mencapai stasioneritas dalam varians dapat dilakukan dengan *power transformation* (λ) yaitu (Wei, 1990: 85):

$$T(X_t) = \begin{cases} \frac{X_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln X_t, & \lambda = 0 \end{cases} \quad (2.22)$$

dengan (λ) adalah parameter transformasi. Secara umum, berikut adalah nilai dari (λ) beserta pendekatan transformasi yang digunakan (Wei, 1994: 85).

Tabel 2.1 Transformasi Box-Cox

Nilai λ Estimate	Transformasi
-1	$\frac{1}{X_t}$
-0,5	$\frac{1}{\sqrt{X_t}}$
0	$\ln X_t$
0,5	$\sqrt{X_t}$
1	X_t (stasioner)

I. *Autoregressive Integrated Moving Average (ARIMA)*

ARIMA (Autoregressive Integrated Moving Average) sering disebut juga metode deret berkala Box-Jenkins. Sedangkan model *ARIMA* merupakan model yang secara penuh mengabaikan variabel independen dalam membuat peramalan. *ARIMA* menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan

peramalan jangka pendek yang akurat dan cocok digunakan jika observasi dari deret berkala saling berhubungan satu sama lain.

Model Box-Jenkins *ARIMA* dibagi dalam tiga kelompok yaitu model *autoregressive* (*AR*), model *moving average* (*MA*) dan model campuran *ARMA* yang mempunyai karakteristik dari dua model pertama.

1. Model *Autoregressive* (*AR*)

Autoregressive adalah suatu bentuk persamaan regresi tetapi bukan yang menghubungkan variabel tak bebas dengan variabel bebas, melainkan menghubungkan nilai-nilai sebelumnya dengan diri sendiri (masing-masing variabel) pada *time lag* (selang waktu) yang bermacam-macam. Jadi suatu model *AR* dikatakan mengikuti proses *AR* jika lag-lag pada plot (*ACF*) menurun secara eksponensial dan banyaknya lag yang signifikan berbeda dengan nol pada plot (*PACF*) digunakan sebagai indikasi parameter *p*. Bentuk umum model *autoregressive* dengan berorde ke-*p* *AR*(*p*) atau model *ARIMA*(*p*,0,0) dinyatakan sebagai berikut: (Makridakis:1999:385)

$$X_t = \mu' + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t \quad (2.23)$$

dengan

μ' = nilai konstan

ϕ_j = parameter autoregresif ke-*j*

e_t = nilai kesalahan pada saat *t*

Dua kasus yang sering dihadapi adalah apabila $p = 1$ dan $p = 2$ yaitu berturut-turut untuk model $AR(1)$ dan $AR(2)$. Dua kasus ini dapat ditulis persamaannya sebagai berikut :


i. $AR(1)$ atau $ARIMA(1,0,0)$

$$X_t = \mu' + \phi_1 X_{t-1} + e_t \quad (2.24)$$

Dengan menggunakan simbol operator *shift* mundur, B , persamaan (2.24) dapat ditulis kembali menjadi :

$$\begin{aligned} X_t - \phi_1 X_{t-1} &= \mu' + e_t \\ \text{atau} & \\ (1 - \phi_1 B)X_t &= \mu' + e_t \end{aligned} \quad (2.25)$$

Berikut adalah bentuk plot *ACF* dan *PACF* model *AR* (1) (Wei, 1990:35).



Gambar 2.6 Plot ACF dan PACF Model AR (1)

Gambar 2.6 menunjukkan pola ACF dan PACF model AR (1). Terlihat pada gambar bahwa ACF menurun mendekati nol dan plot PACF signifikan pada lag pertama.


ii. AR(2) atau ARIMA(2,0,0)

$$X_t = \mu' + \phi_1 X_{t-1} + \phi_2 X_{t-2} + e_t \quad (2.26)$$

Dengan menggunakan simbol operator *shift* mundur, B , persamaan (2.27) dapat ditulis kembali menjadi :

$$\begin{aligned} X_t - \phi_1 X_{t-1} - \phi_2 X_{t-2} &= \mu' + e_t \\ \text{atau} \\ (1 - \phi_1 B - \phi_2 B^2) X_t &= \mu' + e_t \end{aligned} \quad (2.28)$$

Berikut bentuk plot *ACF* dan *PACF* untuk model *AR* (2), (Wei, 1990:44).



Gambar 2.7 Plot *ACF* dan *PACF* Model *AR* (2)

2. Model *Moving Average* (*MA*)

Moving Average atau rata-rata bergerak berarti bahwa nilai deret berkala pada waktu t dipengaruhi oleh unsur kesalahan pada saat ini dan (mungkin) unsur kesalahan pada masa lalu. Suatu deret berkala dikatakan mengikuti proses *MA*, jika lag-lag pada plot *PACF* menurun secara eksponensial dan banyaknya lag yang signifikan berbeda dengan nol pada *ACF* digunakan sebagai indikasi besarnya

parameter q . Bentuk umum model *moving average* orde ke- q $MA(q)$ atau $ARIMA(0,0,q)$ dapat ditulis sebagai berikut: (Makridakis:1999:389)

$$X_t = \mu + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.29)$$

dengan

μ = nilai konstan

θ_1 sampai θ_q = parameter-parameter *moving average*


e_{t-k} = nilai kesalahan pada saat $t-k$

Dalam praktek, dua kasus yang sering dihadapi adalah apabila $q = 1$ dan $q = 2$ yaitu berturut-turut untuk model $MA(1)$, dan $MA(2)$. Persamaan dua kasus tersebut dapat ditulis sebagai berikut :

i. $ARIMA(0,0,1)$ atau $MA(1)$

$$X_t = \mu + (1 - \theta_1 B)e_t \quad (2.30)$$

Berikut gambar plot *ACF* dan *PACF* model *MA* (1), (Suhartono, 2005: 50).




Gambar 2.8 Plot *ACF* dan *PACF* Model *MA* (1)

Gambar 2.8 menunjukkan bahwa pola plot *ACF* dan *PACF* pada model *MA* (1), yaitu plot *ACF* signifikan pada di lag pertama dan *PACF* menurun mendekati nol.

ii. *ARIMA*(0,0,2) atau *MA*(2)

$$X_t = \mu + (1 - \theta_1 B - \theta_2 B^2)e_t \quad (2.31)$$

Berikut bentuk plot *ACF* dan *PACF* model *MA* (2), (Suhartono, 2005: 54)



Gambar 2.9 Plot ACF dan PACF Model MA(2)

3. Model Campuran *Autoregressive Moving Average (ARMA)*

Suatu perluasan yang diperoleh dari model AR dan MA adalah model campuran *ARMA*. Bentuk umum untuk model campuran *ARMA(p,q)* dapat ditulis sebagai berikut:

$$X_t = \mu' + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.32)$$

$$X_t - \phi_1 X_{t-1} - \dots - \phi_p X_{t-p} = \mu' + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}$$

$$(1 - \phi_1 B - \dots - \phi_p B^p) X_t = \mu' + (1 - \theta_1 B - \dots - \theta_q B^q) e_t$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$$

$$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$$

Maka model tersebut dapat ditulis sebagai berikut:

$$\phi_p(B) X_t = \mu' + \theta_q(B) e_t \quad (2.33)$$

Makridakis(1999:392) persamaan untuk kasus yang paling sederhana proses $AR(1)$ murni dan proses $MA(1)$ murni adalah sebagai berikut:

$ARMA(1,1)$ atau $ARIMA(1,0,1)$

$$X_t = \mu' + \phi_1 X_{t-1} + e_t - \theta_1 e_{t-1} \quad (2.34)$$













$$X_t - \phi_1 X_{t-1} = \mu' + e_t - \theta_1 e_{t-1}$$

$$(1 - \phi_1 B)X_t = \mu' + (1 - \theta_1 B)e_t \quad (2.35)$$

$$\begin{array}{ccc} \uparrow & & \uparrow \\ AR(1) & & MA(1) \end{array}$$

Berikut adalah bentuk plot *ACF* dan *PACF* model *ARMA*(1,1) (Suhartono, 2005:

60)



a. ACF

b. PACF

Gambar 2.10 Plot ACF dan PACF Model ARMA(1,1)

Apabila nonstasioneritas ditambahkan pada campuran proses ARMA maka menjadi model umum $ARIMA(p,d,q)$. Jika dilakukan proses pembedaan dengan ordo ke-d yakni $X_t^d = (1 - B)^d X_t$ sehingga X_1, X_2, \dots menjadi data deret berkala stasioner, maka model ARMA(p,q) pada X_t dinamakan model $ARIMA(p,d,q)$. Suatu proses ARIMA dapat digambarkan dengan dimensi p,d,q dengan :

AR : p = orde dari proses *autoregresif*

I : d = tingkat perbedaan (*degree of differencing*)

MA : q = orde dari proses *moving average*

Bentuk umum model ARIMA (p,d,q) adalah sebagai berikut

$$\phi_p(B)(1 - B)^d X_t = \mu' + \theta_q(B)e_t \quad (2.36)$$

dengan operator AR(p) dinyatakan dalam bentuk polinomial

$$\phi_p(B) = (1 - \phi_1 B + \phi_2 B^2 + \dots + \phi_p B^p) \quad (2.37)$$

dan operator MA(q) adalah

$$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \quad (2.38)$$

Parameter d menunjukkan bahwa proses tidak stasioner. Jadi apabila parameter $d = 0$ maka proses telah stasioner. Namun dalam prakteknya jarang diperlukan pemakaian nilai p , d , q selain 0, 1 atau 2. Persamaan untuk khusus yang paling sederhana, $ARIMA(1,1,1)$ adalah sebagai berikut:

$$(1 - B)(1 - \phi_1 B)X_t = \mu' + (1 - \theta_1 B)e_t \quad (2.39)$$

↑

↑

↑

Pembedaan $AR(1)$ $MA(1)$
 pertama

J. Langkah-langkah Pemodelan *ARIMA*

Metode Box-Jenkins (*ARIMA*) dapat dilakukan melalui beberapa tahap

1. Identifikasi Model

Identifikasi model berkaitan dengan penentuan order pada *ARIMA*. Oleh karena itu, identifikasi model dilakukan setelah melakukan analisis deret berkala untuk mengetahui adanya autokorelasi dan kestasioneran data sehingga dapat diketahui perlu tidaknya dilakukan transformasi dan pembedaan. Jika data tidak stasioner dalam hal varians maka dapat dilakukan suatu transformasi dan jika data tidak stasioner dalam hal rata-rata maka dilakukan pembedaan. Langkah pertama yang baik untuk menganalisis data deret berkala adalah dengan membuat plot data *time*

series terlebih dahulu. Hal ini bermanfaat untuk mengetahui adanya trend dan pengaruh musiman pada data tersebut. Langkah selanjutnya adalah menganalisis koefisien autokorelasi dan koefisien autokorelasi parsialnya dengan tujuan mengetahui kestasioneran data dalam rata-rata dan dari plot *ACF*, *PACF* tersebut dapat diidentifikasi order model *ARMA*nya.

2. Estimasi Parameter Model

Menurut Makridakis(1999:407) dalam mendapatkan penaksiran parameter ada 2 cara yang mendasar yaitu:

- a. Dengan cara mencoba-coba, yaitu menguji beberapa nilai yang berbeda dan memilih satu nilai tersebut (atau sekumpulan nilai, apabila terdapat lebih dari satu parameter yang akan ditaksir) yang meminimumkan jumlah kuadrat nilai sisa.
- b. Perbaikan secara iteratif dengan memilih taksiran awal dan kemudian membiarkan program komputer memperhalus penaksiran tersebut secara interaktif.

Setelah dilakukan estimasi parameter maka parameter tersebut perlu diuji signifikansinya untuk mengetahui apakah parameter tersebut dapat dimasukkan dalam model dengan uji hipotesis sebagai berikut:

AR(Autoregressive)

$H_0 : \phi_i = 0$, dimana $i = 1, 2, \dots, k$ (*AR* tidak signifikan dalam model)

$H_1 : \phi_i \neq 0$ (*AR* signifikan dalam model)

MA(Moving Average)

$H_0 : \theta_i = 0$, dimana $i = 1, 2, \dots, k$ (MA tidak signifikan dalam model)

$H_1 : \theta_i \neq 0$ (MA signifikan dalam model)

Statistik uji yang digunakan adalah sebagai berikut:

$$t_{hitung}^{AR} = \frac{\hat{\phi}_k}{SE(\hat{\phi}_k)} \quad (2.40)$$

$$t_{hitung}^{MA} = \frac{\hat{\theta}_k}{SE(\hat{\theta}_k)} \quad (2.41)$$

dengan $\hat{\phi}_k$ adalah estimator dari ϕ_k dan $\hat{\theta}_k$ adalah estimator dari θ_k sedangkan $SE(\hat{\phi}_k)$ adalah standar eror yang diestimasi dari ϕ_k .

Kriteria keputusan untuk menolak H_0 adalah jika $|t| > t_{\frac{\alpha}{2}, df}$, $df = n - np$ dengan np

banyaknya parameter dan n banyak pengamatan atau tolak H_0 jika $p\text{-value} < 0,05$

3. Pemeriksaan Diagnostik pada Model

Pemeriksaan diagnostik merupakan salah satu tahap dalam pemodelan data deret berkala. Tahap ini bertujuan untuk memeriksa apakah model estimasi sudah sesuai yaitu model sudah memenuhi syarat *white noise*. Biasanya dalam pemodelan *ARIMA* dibentuk lebih dari satu model kemudian dilakukan perbandingan untuk mengetahui model mana yang lebih baik

4. Kriteria Pemilihan Model

Tahap selanjutnya setelah dilakukan identifikasi, estimasi parameter dan diagnostik model adalah pemilihan kriteria model jika terdapat dua atau lebih model deret berkala. Tujuannya adalah untuk memilih model mana yang layak digunakan

dalam peramalan. Salah satu pendekatan yang dapat digunakan dalam pemilihan model yaitu pendekatan *AIC* (*Akaike's Information Criterion*). Nilai *AIC* semakin kecil maka model yang didapatkan semakin baik. Berikut adalah persamaan *AIC* (Hanke dan Wichern, 1992:413):

$$AIC = \ln(\hat{\sigma}^2) + \frac{2}{n}r \quad (2.42)$$

dengan n = banyak pengamatan residual,
 $\hat{\sigma}^2$ = jumlah kuadrat residual dibagi banyak pengamatan.
 r = banyaknya parameter dalam model *ARIMA*

K. Seasonal Autoregressive Integrated Moving Average (SARIMA)

Deret berkala musiman yaitu deret berkala yang mempunyai sifat berulang setelah beberapa periode waktu tertentu, misalnya satu tahun, satu bulan, triwulanan dan seterusnya. Oleh karena itu, deret berkala musiman mempunyai karakteristik yang ditunjukkan adanya korelasi yang kuat. Model *ARIMA* musiman atau model *SARIMA* (*Seasonal Autoregressive Integrated Moving Average*) secara umum ditulis dalam bentuk sebagai berikut: (Chatfield, 2004:66)

$$ARIMA(p,d,q)(P,D,Q)^S$$

$$\phi_p(B)\Phi_p(B^S)(1-B)^d(1-B^S)^D X_t = \mu + \theta_q(B)\Theta_q(B^S)e_t \quad (2.43)$$

$$X_t = \frac{\mu + \theta_q(B)\Theta_q(B^S)e_t}{\phi_p(B)\Phi_p(B^S)(1-B)^d(1-B^S)^D} \quad (2.44)$$

dengan:

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p), \text{ parameter AR nonseasonal}$$

$$\Phi_p(B^S) = (1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_p B^{QS}), \text{ parameter } AR \text{ seasonal}$$


$$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q), \text{ parameter } MA \text{ nonseasonal}$$

$$\Theta_Q(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}), \text{ parameter } MA \text{ seasonal}$$

μ = konstanta

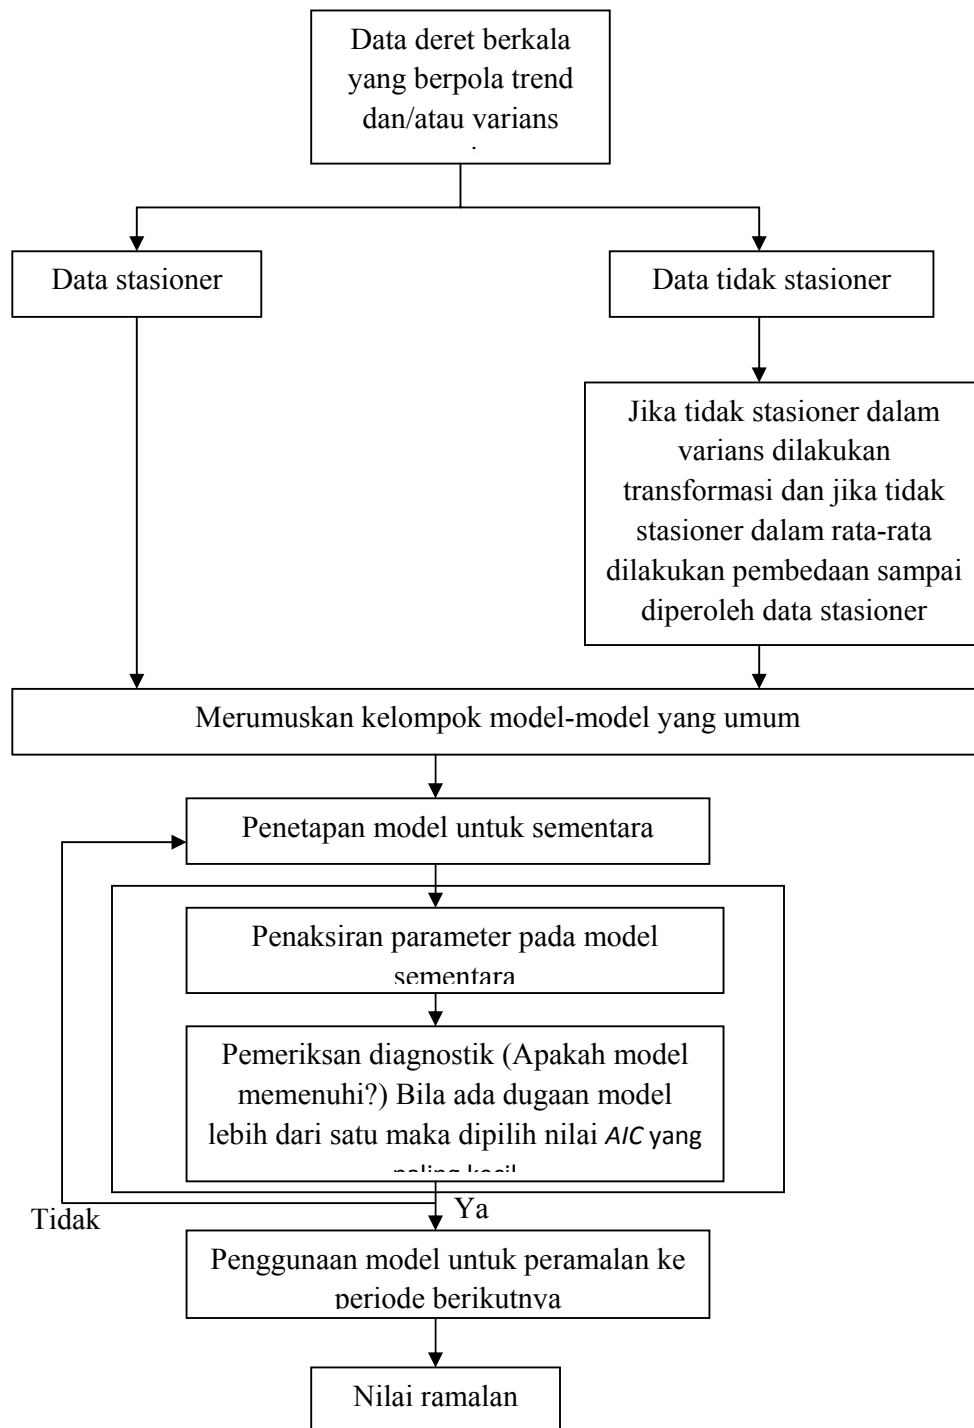
S = banyak periode per musim

Berikut adalah contoh gambar plot *time series* dan plot *ACF* yang terdapat pola musiman dengan periode musiman.



Gambar 2.11 Plot *Time series* dan *ACF* Pola Musiman

Prosedur identifikasi, estimasi parameter, *diagnostic checking* dan peramalan pada model *ARIMA* musiman tidak berbeda dari prosedur pembentukan model *ARIMA* untuk data deret berkala tidak musiman. Berikut merupakan langkah-langkah pembentukan model *ARIMA* yang disajikan dalam bentuk diagram alir.

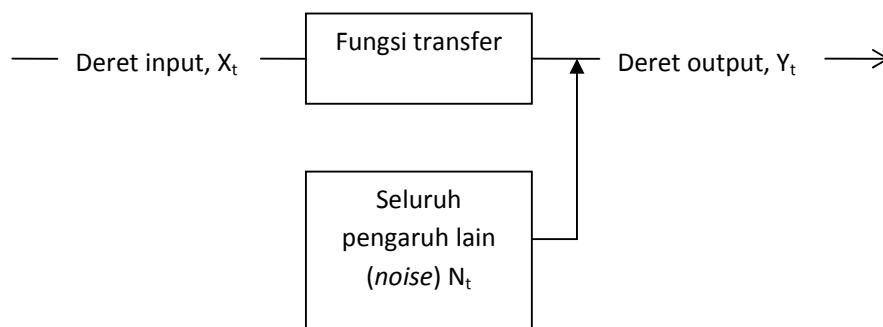


Gambar 2.12 Diagram Alir Langkah-langkah Pemodelan ARIMA

BAB III

PEMBAHASAN

Model fungsi transfer multivariat merupakan gabungan dari model *ARIMA univariat* dan analisis regresi berganda sehingga menjadi suatu model yang mencampurkan pendekatan deret berkala dengan pendekatan kausal. Beberapa hal yang berkaitan dengan model fungsi transfer antara lain deret berkala output, disebut Y_t , yang diperkirakan akan dipengaruhi oleh deret berkala input, disebut X_t , dan input-input lain yang digabungkan dalam satu kelompok yang disebut gangguan (*noise*) N_t . Seluruh sistem tersebut adalah sistem yang dinamis, dengan kata lain deret input memberikan pengaruhnya kepada deret output melalui fungsi transfer. Konsep fungsi transfer ditunjukkan pada gambar 3.1 berikut:



Gambar 3.1 Konsep Fungsi Transfer

A. Model Fungsi Transfer

Model fungsi transfer bivariat ditulis dalam dua bentuk umum. Bentuk pertama adalah sebagai berikut: (Makridakis, dkk:1999:448)

$$Y_t = v(B)X_t + N_t \quad (3.1)$$

dengan Y_t = deret output

X_t = deret input

N_t = pengaruh kombinasi dari seluruh faktor yang mempengaruhi Y_t

$v(B) = (v_0 + v_1B + v_2B^2 + \dots + v_kB^k)$ k adalah orde fungsi transfer

Deret input dan output pada persamaan (3.1) dapat ditransformasikan atau dibedakan agar menjadi stasioner, untuk membedakan persamaan yang telah ditransformasi dan dibedakan maka nilai X_t , Y_t , dan N_t pada persamaan ditulis dengan huruf kecil.

Orde dari fungsi transfer adalah k (menjadi orde tertinggi untuk proses pembedaan) dan terkadang nilai k lebih besar dari banyaknya lag pada korelasi silang oleh karena itu nilai k tidak terlalu dibatasi. Dari alasan tersebut maka persamaan model fungsi transfer juga ditulis sebagai berikut:

$$v(B) = \frac{\omega(B)}{\delta(B)} \quad (3.2)$$

dan

$$n_t = \frac{\theta(B)}{\phi(B)} a_t \quad (3.3)$$

sehingga

$$y_t = \frac{\omega(B)}{\delta(B)} x_{t-b} + \frac{\theta(B)}{\phi(B)} a_t \quad (3.4)$$

dengan

$$\omega(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s,$$

$$\delta(B) = 1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r,$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q,$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p,$$

y_t = nilai Y_t yang telah ditransformasikan dan dibedakan

x_t = nilai X_t yang telah ditransformasikan dan dibedakan

a_t = nilai gangguan random

r, s, p, q, b = konstanta

Pada fungsi transfer multivariat atau multi input ada beberapa variabel input X yang dimasukkan pada suatu pemodelan. Bentuk umum persamaan model fungsi transfer multivariat adalah sebagai berikut : (Wei, 1990:362)

$$y_t = \sum_{j=1}^k v_j(B) x_{jt} + n_t \quad (3.5)$$

dimana

$v_j(B) = \omega_j(B) B^{bj} / \delta_j(B)$ adalah fungsi transfer ke-j untuk deret input x_{jt} dan a_t

diasumsikan saling bebas dengan deret input x_{jt} , $j = 1, 2, \dots, k$. Persamaan (3.5) dapat pula ditulis sebagai berikut:

$$y_t = \sum_{j=1}^m [\delta_j(B)]^{-1} \omega_j(B) B^{bj} x_{jt} + [\phi(B)]^{-1} \theta(B) a_t \quad (3.6)$$

dengan

y_t = variabel dependen

x_{jt} = variabel independent ke-j

$\omega_j(B)$ = operator *moving average* order s_j untuk variabel ke-j

$\delta_j(B)$ = operator *autoregresi* order r_j untuk variabel ke-j

$\theta(B)$ = operator *moving average* order q

$\phi(B)$ = operator *autoregresi* order p

a_t = nilai gangguan acak

Jika deret input x_{it} dan x_{jt} tidak berkorelasi untuk $i \neq j$ maka analisis dan perhitungan sama seperti model fungsi transfer input tunggal sedangkan untuk deret multivariat x_{it} dan x_{jt} dengan $i \neq j$ yang saling berkorelasi maka dilakukan analisis korelasi silang (*cross correlation*) antar deret berkala untuk mengetahui deret mana yang harus dikeluarkan dari model.

B. Prosedur untuk Menentukan Model Fungsi Transfer Multivariat

Tahap-tahap dalam pemodelan fungsi transfer multivariat untuk deret input (X_t) dan deret output (Y_t) adalah dengan cara mengidentifikasi deret input tunggal terlebih dahulu supaya mendapatkan order model *ARIMA*. Setelah didapatkan model *ARIMA* untuk deret input tunggal dan deret output selanjutnya dilakukan pemutihan dan dilanjutkan dengan perhitungan korelasi silang untuk masing-masing deret input dengan output yang berguna untuk menentukan nilai r, s, b . Sebagaimana Liu dan Hanssens (1982) menyarankan suatu prosedur identifikasi simultan yang menggunakan kuadrat terkecil umum untuk mengestimasi bobot respons impuls. Setelah estimasi bobot-bobot respons impuls diperoleh baru dapat mengidentifikasi bentuk model fungsi transfer dan *noise* gabungan. Berikut dipaparkan prosedur pemodelan fungsi transfer multivariat. (Makridakis, dkk:1999:450)

1. Tahap Pertama : Identifikasi Bentuk Model Input Tunggal

1.1. Mempersiapkan deret input dan output

Pada tahap ini yang perlu dilakukan adalah mengidentifikasi kestasioneran deret input dan output. Untuk menghilangkan ketidakstasioneran maka perlu mentransformasi atau melakukan perbedaan deret-deret input dan output. Transformasi yang biasa diterapkan adalah dalam bentuk (Makridakis, 1999:451)

$$X'_t = \begin{cases} (X_t + m)^\lambda, \lambda \neq 0 \\ \log(X_t + m), \lambda = 0 \end{cases} \quad (3.7)$$

dan perbedaan yang biasa diterapkan adalah dalam bentuk pada persamaan (2.21)

1.2. Pemutihan deret input

Pemutihan deret input bertujuan untuk menjadikan deret input menjadi lebih dapat diatur dengan menghilangkan seluruh pola yang diketahui supaya yang tertinggal hanya *white noise*. Pemutihan deret input x_t dengan proses $ARIMA(p_x, 0, q_x)$ adalah

$$\phi_x(B)x_t = \theta_x(B)\alpha_t \quad (3.8)$$

Mengubah deret input x_t menjadi deret α_t sebagai berikut:

$$\frac{\phi_x(B)}{\theta_x(B)}x_t = \alpha_t \quad (3.9)$$

1.3. “Pemutihan” deret output

Apabila suatu transformasi pemutihan dilakukan untuk x_t maka transformasi yang sama juga harus diterapkan terhadap y_t supaya fungsi transfer dapat memetakan x_t kedalam y_t . Transformasi pada y_t tidak harus mengubah y_t menjadi *white noise*. Berikut merupakan deret y_t yang telah “diputihkan” :

$$\frac{\phi_x(B)}{\theta_x(B)} y_t = \beta_t \quad (3.10)$$

1.4. Perhitungan korelasi silang dan autokorelasi deret input dan deret output yang telah diputihkan

Di dalam memodelkan *ARIMA* univariat koefisien autokorelasi merupakan statistik yang membantu menetapkan model. Sedangkan dalam memodelkan fungsi transfer autokorelasi memerankan peranan kedua untuk koefisien korelasi silang. Fungsi korelasi silang adalah ukuran kekuatan hubungan antar dua variabel. Korelasi silang antara X dan Y menentukan tingkat hubungan antar nilai X pada waktu t dengan nilai y pada waktu t+k (Makridakis,1999:456). Koefisien korelasi silang dari input x_t dan output y_t untuk lag ke-k didefinisikan sebagai berikut:

$$r_{xy} = \hat{\rho}_{xy}(k) = \frac{C_{xy}(k)}{\sqrt{C_{xx}(0)C_{yy}(0)}} = \frac{C_{xy}(k)}{S_x S_y} \quad (3.11)$$

dengan

$$C_{xy}(k) = \frac{1}{n} \sum_{t=1}^{n-k} (X_t - \bar{X})(Y_{t+k} - \bar{Y}) \quad (3.12)$$

sehingga r_{xy} menjadi

$$r_{xy} = \frac{\frac{1}{n} \sum_{t=1}^{n-k} (X_t - \bar{X})(Y_{t+k} - \bar{Y})}{\sqrt{\frac{1}{n} \sum_{t=1}^n (X_t - \bar{X})^2 \sum_{t=1}^n (Y_t - \bar{Y})^2}} \quad (3.13)$$

Rumus kesalahan standar berikut berguna untuk memeriksa apakah $r_{xy}(k)$ berbeda nyata dari nol dengan membandingkan nilai $r_{xy}(k)$ dengan kesalahan standar. (Wei,1990:330)

$$SE_{r_{xy}(k)} = \frac{1}{\sqrt{n-k}} \quad (3.14)$$

Di dalam model fungsi transfer multivariat perhitungan korelasi silang pada masing-masing input x terhadap output y digunakan untuk mengetahui nilai r,s,b yang diidentifikasi dari plot korelasi silang. Setelah didapatkan nilai r,s,b pada masing-masing input maka barulah dilakukan korelasi silang serentak antara nilai y terhadap seluruh variabel inputnya.

1.5. Penaksiran langsung bobot respon impuls

Langkah selanjutnya setelah perhitungan korelasi silang adalah penaksiran nilai bobot respon impuls. Bobot respon impuls ini berguna untuk menghitung deret

noise. Untuk penaksiran bobot respon impuls secara langsung rumusnya adalah sebagai berikut:

$$v_k = r_{\alpha\beta}(k) \frac{S_\beta}{S_\alpha} \quad (3.15)$$

dengan

$r_{\alpha\beta}(k)$ adalah nilai dari korelasi silang lag ke-k

S_β adalah standar deviasi dari deret output yang telah diputihkan

S_α adalah standar deviasi dari deret input yang telah diputihkan

1.6. Penetapan (r,s,b) untuk model fungsi transfer yang menghubungkan deret input dan deret output

Tiga parameter kunci dalam model fungsi transfer adalah (r,s,b) dimana r menunjukkan ordo fungsi $\delta(B)$, s menunjukkan ordo fungsi $\omega(B)$ dan b menunjukkan keterlambatan yang dicatat pada x_{t-b} pada persamaan

$$y_t = \frac{\omega(B)}{\delta(B)} x_{t-b} + \frac{\theta(B)}{\phi(B)} \alpha_t \quad (3.16)$$

Berikut ini beberapa aturan yang dapat digunakan untuk menduga nilai r, s, b dari suatu fungsi transfer. (Wei,1994;324)

- a. Nilai b menyatakan bahwa y_t tidak dipengaruhi oleh x_t sampai periode $t+b$.

Besarnya b dapat ditentukan dari lag yang pertama kali signifikan pada plot korelasi silang. Nilai ini merupakan yang paling mudah untuk ditentukan apabila korelasi silang diperoleh dari $r_{\alpha\beta}(0) = r_{\alpha\beta}(1) = r_{\alpha\beta}(2) = 0$ tetapi $r_{\alpha\beta}(3) = 0,5$ maka

dapat ditentukan $b = 3$, dengan kata lain terdapat tiga periode sebelum deret berkala input α mulai mempengaruhi deret berkala output β

b. Nilai s menyatakan seberapa lama deret y_t terus dipengaruhi $x_{t-b-1}, x_{t-b-2}, \dots, x_{t-b-s}$ sehingga dapat dikatakan bahwa nilai s adalah bilangan pada lag plot korelasi silang sebelum terjadinya pola menurun.

c. Nilai r menyatakan bahwa y_t dipengaruhi oleh nilai masa lalunya y_{t-1}, \dots, y_{t-r}

$r = 0$ bila ada beberapa lag plot pada korelasi silang yang terpotong.

$r = 1$ bila plot pada korelasi silang menunjukkan suatu pola eksponensial menurun.

$r = 2$ bila plot pada korelasi silang menunjukkan suatu pola eksponensial menurun dan pola sinus.

Berikut beberapa bentuk fungsi transfer yang umum digunakan dalam peramalan:

Tabel 3.1. Model Fungsi Transfer dengan $r = 0$

(r,s,b)	Fungsi transfer
$(0,0,2)$	$v(B)x_t = \omega_0 x_{t-2}$
$(0,1,2)$	$v(B)x_t = (\omega_0 - \omega_1 B)x_{t-2}$
$(0,2,2)$	$v(B)x_t = (\omega_0 - \omega_1 B - \omega_2 B^2)x_{t-2}$

Tabel 3.2 Model Fungsi Transfer dengan $r = 1$

(r,s,b)	Fungsi transfer
(1,0,2)	$v(B)x_t = \frac{\omega_0}{(1 - \delta_1 B)} x_{t-2}$
(1,1,2)	$v(B)x_t = \frac{(\omega_0 - \omega_1 B)}{(1 - \delta_1 B)} x_{t-2}$
(1,2,2)	$v(B)x_t = \frac{(\omega_0 - \omega_1 B - \omega_2 B^2)}{(1 - \delta_1 B)} x_{t-2}$

Tabel 3.3 Model Fungsi Transfer dengan $r = 2$

(r,s,b)	Fungsi transfer
(2,0,2)	$v(B)x_t = \frac{\omega_0}{(1 - \delta_1 B - \delta_2 B^2)} x_{t-2}$
(2,1,2)	$v(B)x_t = \frac{(\omega_0 - \omega_1 B)}{(1 - \delta_1 B - \delta_2 B^2)} x_{t-2}$
(2,2,2)	$v(B)x_t = \frac{(\omega_0 - \omega_1 B - \omega_2 B^2)}{(1 - \delta_1 B - \delta_2 B^2)} x_{t-2}$

1.7. Penaksiran awal deret gangguan (n_t)

Bobot respon impuls diukur secara langsung dan ini memungkinkan dilakukannya perhitungan nilai taksiran dari deret gangguan n_t dikarenakan

$$n_t = y_t - \hat{y}_t \quad (3.17)$$

$$= y_t - \frac{\hat{\omega}(B)}{\hat{\delta}(B)} B^b x_t \quad (3.18)$$

$$= y_t - \hat{v}(B) x_t \quad (3.19)$$

$$= y_t - v_0 x_t - v_1 x_{t-1} - v_2 x_{t-2} - \dots - v_g x_{t-g} \quad (3.20)$$

1.8. Penetapan (p_n, q_n) untuk model *ARIMA* $(p_n, 0, q_n)$ dari deret gangguan n_t

Sesudah menggunakan persamaan deret gangguan n_t nilai-nilai n_t dianalisis dengan cara *ARIMA* biasa untuk menentukan model *ARIMA* yang tepat sehingga diperoleh nilai p_n dan q_n . Dengan cara ini fungsi $\phi_n(B)$ dan $\theta_n(B)$ untuk deret gangguan n_t dapat diperoleh untuk mendapatkan persamaan

$$\phi_n(B) n_t = \theta_n(B) e_t \quad (3.21)$$

2. Tahap Kedua : Penaksiran Parameter-parameter Model Fungsi Transfer

Langkah kedua setelah mengidentifikasi bentuk model adalah penaksiran parameter-parameter model fungsi transfer input tunggal. Model fungsi transfer sementara yang didapatkan pada persamaan (3.16) perlu dilakukan estimasi parameter

$$\delta = (\delta_1, \dots, \delta_r)', \quad \omega = (\omega_0, \omega_1, \dots, \omega_s)', \quad \phi = (\phi_1, \dots, \phi_p)', \quad \theta = (\theta_1, \dots, \theta_q)' \quad \text{dan}$$

σ_a^2 sehingga persamaan (3.16) dapat ditulis kembali menjadi

$$\delta(B) \phi(B) y_t = \phi(B) \omega(B) x_{t-b} + \delta(B) \theta(B) a_t \quad (3.22)$$

$$c(B) y_t = d(B) x_{t-b} + e(B) a_t \quad (3.23)$$

dimana

$$c(B) = \delta(B)\phi(B) = (1 - \delta_1 B - \dots - \delta_r B^r)(1 - \phi_1 B - \dots - \phi_p B^p) \quad (3.24)$$

$$= (1 - c_1 B - c_2 B^2 - \dots - c_{p+r} B^{p+r}) \quad (3.25)$$

$$d(B) = \phi(B)\omega(B) = (1 - \phi_1 B - \dots - \phi_p B^p)(\omega_0 - \omega_1 B - \dots - \omega_s B^s) \quad (3.26)$$

$$= (d_0 - d_1 B - d_2 B^2 - \dots - d_{p+s} B^{p+s}) \quad (3.27)$$

dan

$$e(B) = \delta(B)\theta(B) = (1 - \delta_1 B - \dots - \delta_r B^r)(1 - \theta_1 B - \dots - \theta_q B^q) \quad (3.28)$$

$$= (1 - e_1 B - e_2 B^2 - \dots - e_{r+q} B^{r+q}) \quad (3.29)$$

jadi diperoleh

$$a_t = y_t - c_1 y_{t-1} - \dots - c_{p+r} y_{t-p-r} - d_0 x_{t-b} + d_1 x_{t-b-1} + \dots + d_{p+s} x_{t-b-p-s} + \\ e_1 a_{t-1} + \dots + e_{r+q} a_{t-r-q} \quad (3.30)$$

dimana c_i , d_j , dan e_k adalah fungsi transfer dari δ_i , ω_j , ϕ_k dan θ_l . Metode penaksiran yang digunakan adalah *Conditional Maximum Likelihood*. Diasumsikan bahwa a_t adalah deret *white noise* dengan berdistribusi normal $N(0, \sigma_a^2)$ sehingga didapatkan fungsi *likelihood*:

$$L(\delta, \omega, \phi, \theta, \sigma_a^2 | b, x, y, x_0, y_0, a_0) = (2\pi\sigma_a^2)^{-n/2} \exp \left[-\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2 \right] \quad (3.31)$$

Secara umum menurut Wei (1990:332) estimasi parameter model fungsi transfer dapat juga menggunakan metode *Conditional Least Squares* dan mengasumsikan residual a_t yang tidak diketahui sama dengan nol, maka estimasi parameter model fungsi transfer didapatkan dengan meminimumkan

$$S(\delta, \omega, \phi, \theta | b) = \sum_{t=t_0}^n a_t^2 . \quad (3.32)$$

3. Tahap Ketiga : Uji Diagnosis Model Fungsi Transfer Input Tunggal

3.1. Perhitungan autokorelasi untuk nilai sisa model (r,s,b) yang menghubungkan deret input dan output

Pengujian kelayakan suatu model perlu dilakukan untuk mengetahui kesesuaian model yaitu sudah memenuhi syarat *white noise*. Caranya adalah dengan memeriksa autokorelasi dan korelasi residualnya. Pengujian autokorelasi untuk nilai sisa menggunakan hipotesis

H_0 : Autokorelasi pada deret sisa a_t tidak signifikan

H_1 : Autokorelasi pada deret sisa a_t signifikan

dengan statistik uji

$$Q = (n - r - s - b) \sum_{k=1}^m r_{a\alpha}^2(k) \quad (3.33)$$

dengan

n = banyaknya pengamatan

m = lag terbesar yang diperhatikan

(r,s,b) = parameter model fungsi transfer

$r_{aa}(k)$ = autokorelasi residual untuk lag k

dan membandingkan hasilnya dengan tabel distribusi χ^2 dengan taraf signifikansi α dan derajat bebas $m-p_n-q_n$ (p_n, q_n merupakan nilai *autoregressive* dan *moving average* dari deret *noise*). Tolak H_0 jika $Q \geq \chi^2_{\alpha, df}$

3.2. Perhitungan korelasi silang antara nilai sisa dengan deret gangguan yang telah diputihkan.

Korelasi silang antar deret input dan deret output yang telah diputihkan menggambarkan tingkat hubungan antarderet. Korelasi silang dapat dikonversi ke dalam estimasi bobot respons impuls. Susunan dalam bobot-bobot respons impuls mengindikasikan bentuk model fungsi transfer sementara, dengan menggunakan bobot-bobot respons impuls ini dapat membangkitkan suatu estimasi deret *noise* awal dari model fungsi transfer.

Fungsi respons impuls mengukur besarnya korelasi antara x dan y . Fungsi korelasi silang mirip dengan fungsi autokorelasi dan fungsi autokorelasi parsial dalam menghitung korelasi tetapi korelasi silang mempunyai nilai tertentu untuk lag ke-0 sedangkan fungsi autokorelasi sendiri adalah sebesar satu.

Pengujian korelasi silang antara nilai sisa dengan deret gangguan yang telah diputihkan menggunakan statistik uji Q dengan hipotesis

H_0 : Korelasi silang antara deret a_t dan α_t tidak signifikan

H_1 : Korelasi silang antara deret a_t dan α_t signifikan

$$Q = (n - n^*) \sum_{k=1}^m r_a^2(k) \quad (3.34)$$

dengan

m = lag maksimum

n^* = nilai $(s + b + p_x)$ dimana p_x adalah banyak parameter *AR* pada model *ARIMA* dengan deret input (x_t)

Hasilnya dibandingkan dengan tabel χ^2 dengan derajat bebas $m-r-s$ dengan

kriteria keputusan tolak H_0 jika $Q \geq \chi_{\alpha, df}^2$

4. Tahap Keempat : Penentuan Model Fungsi Transfer Multivariat

Pemodelan fungsi transfer multivariat dilakukan dengan cara memodelkan secara serentak seluruh variabel yang sudah diidentifikasi sebelumnya. Identifikasi nilai-nilai bobot respons impuls dan korelasi silang dijadikan dasar dalam pemodelan serentak yang menghasilkan fungsi transfer multivariat. Cara yang dilakukan dalam model fungsi transfer multivariat sama halnya yang dilakukan pada model input tunggal. Adapun langkah-langkahnya sebagai berikut:

1. Mengidentifikasi deret input dan output untuk mengetahui kestasioneran dan menentukan order model *ARIMA*.

2. Menghitung estimasi parameter model *ARIMA* yang sesuai untuk masing-masing deret input. Lalu dilakukan uji untuk mengetahui model memenuhi proses *white noise* atau belum.
3. Dilakukan korelasi silang untuk masing-masing deret input terhadap deret output. Korelasi silang berguna untuk menghitung deret *noise* dan juga menentukan order model fungsi transfer yakni dengan mengidentifikasi plot korelasi silangnya.
4. Menentukan nilai r, s, b pada masing-masing deret input dan menghitung nilai gangguan (n_t) sehingga model fungsi transfer input tunggal selesai terbentuk. Tahapan tersebut merupakan pembentukan model fungsi transfer input tunggal.

Sedangkan untuk model fungsi transfer multivariate dilanjutkan dengan cara:

5. Nilai r, s, b pada masing-masing deret input yang telah didapat lalu dilakukan estimasi secara serempak dengan metode penaksiran yang digunakan adalah *conditional least square estimation*.
6. Sedangkan nilai gangguan gabungannya didapat dari rumus

$$n_t = y_t - \hat{y}_t \quad (3.35)$$

$$= y_t - \sum_{j=1}^k \hat{v}_j(B)x_{jt}$$

Estimasi yang dilakukan dalam model fungsi transfer ini menggunakan alat bantu program SAS.

Nilai-nilai (r, s, b) yang telah diidentifikasi dalam model fungsi transfer input tunggal dijumlahkan sehingga model multivariat menjadi

$$y_t = \sum_{j=1}^m \frac{\omega_j(B)}{\delta_j(B)} B^{bj} x_{jt} + \frac{\theta(B)}{\phi(B)} a_t \quad (3.36)$$


C. Penerapan Model Fungsi Transfer Multivariat dalam Peramalan Curah Hujan

Di dalam penulisan ini model fungsi transfer multivariat akan diaplikasikan pada data curah hujan di Kota Yogyakarta dengan variabel input yang digunakan yaitu tekanan udara, kelembaban udara, suhu udara dan kecepatan angin dengan data yang digunakan bersumber dari BPS Kota Yogyakarta mulai dari periode Januari 2002 sampai Desember 2009. Untuk lebih jelasnya akan dipaparkan tahap demi tahap pembentukan model fungsi transfer multivariat yang pada tahap akhir dapat digunakan sebagai peramalan. Tahap pertama untuk pembentukan model fungsi transfer multivariat adalah melalui pembentukan model input tunggal atau bivariat yang kemudian dilakukan perhitungan serempak untuk memperoleh model fungsi transfer multivariat. Berikut prosedur dalam model fungsi transfer multivariat


1. Tahap Pertama : Identifikasi Bentuk Model Input Tunggal

1.1 Mempersiapkan deret input dan output

Pertama-tama akan diidentifikasi terlebih dahulu deret outputnya. Berikut merupakan plot *time series*, *ACF* dan *PACF* dari data curah hujan.




Gambar 3.2 Plot *Time Series* Data Curah Hujan



Gambar 3.3 Plot ACF dan PACF Data Curah Hujan Menunjukkan Data Belum Stasioner dalam Rata-rata dan Varians

Gambar 3.2 menunjukkan plot *time series* dari data curah hujan yang berfluktuasi tajam. Terlihat bahwa terdapat pola musiman di dalam data dan ada kecenderungan variasi musim yang menyebabkan hal itu terjadi karena curah hujan memang merupakan fenomena musiman.


Hal ini didukung oleh plot ACF yang menunjukkan data curah hujan tidak stasioner dalam rata-rata. Berdasarkan plot *time series* terlihat adanya perubahan nilai pada varians sehingga menunjukkan bahwa curah hujan juga belum stasioner dalam varians. Terdapat adanya pola musiman pada data curah hujan tersebut. Pada lag 1, 6 dan 12 berbeda nyata dengan nol hal itu menunjukkan adanya pola musiman. Untuk menstasionerkan data tersebut maka dilakukan pembeda, oleh karena data tersebut menunjukkan adanya pola musiman maka pembeda pada lag 12. Berikut adalah plot ACF dan PACF data curah hujan pada pembeda duabelas.




Gambar 3.4 Plot ACF dan PACF Data Curah Hujan Setelah Dilakukan Pembeda Duabelas ($d = 12$)

Berdasarkan deskripsi plot ACF dan PACF di atas pada pembeda duabelas menyebabkan data curah hujan cenderung stasioner yang ditunjukkan oleh nilai ACF dan PACF yang menurun serta menunjukkan adanya pola musiman yang dapat dilihat pada lag 12 yang keluar dari garis signifikan. Bila diidentifikasi order model ARIMA pada curah hujan plot ACF dan PACF menunjukkan model $MA(1)$ atau $AR(1)$ untuk pola musiman dan plot PACF memperlihatkan $AR(1)$ untuk pola tidak musimannya

Selanjutnya adalah mengidentifikasi untuk deret inputnya. Pada gambar di bawah ini menampilkan plot *time series* data masing-masing deret input, plot ACF, dan PACF untuk mengetahui deret input tersebut sudah stasioner atau belum.

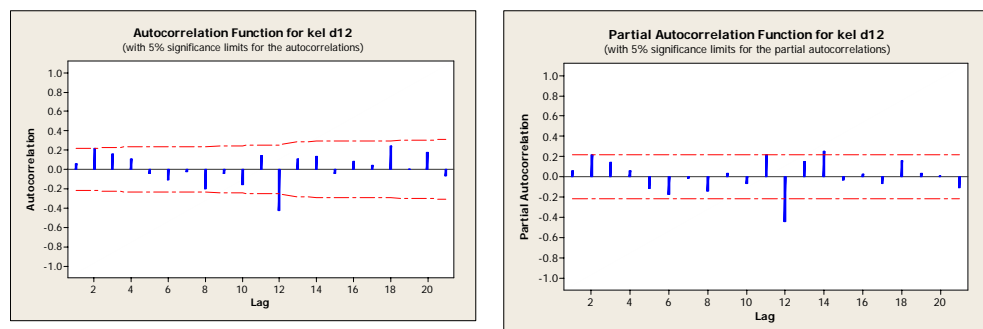


Gambar 3.5 Plot Time Series Data Kelembaban Udara




Gambar 3.6 Plot ACF dan PACF Data Kelembaban Udara Menunjukkan Data Belum Stasioner dalam Rata-rata dan Varians

Pada gambar 3.5 plot *time series* menunjukkan adanya perubahan varians dari waktu ke waktu. Pada plot ACF terlihat bahwa data tidak stasioner dalam rata-rata hal itu terlihat adanya perubahan nilai tengahnya. Selain itu lag 1, 6 dan 12 yang keluar dari garis signifikan pada plot ACF menunjukkan adanya pola musiman di dalamnya sehingga perlu dilakukan pembeda duabelas untuk menstasionerkan data. Berikut adalah plot ACF dan PACF untuk deret input kelembaban udara yang telah dilakukan pembeda agar mendapatkan stasioneritas dalam rata-rata.




Gambar 3.7 Plot ACF dan PACF Data Kelembaban Udara Setelah Dilakukan Pembeda Dua Belas ($d = 12$)

Setelah dilakukan pembeda duabelas plot *ACF* memperlihatkan bahwa data telah stasioner dalam rata-rata, sudah tidak terlihat lagi fluktuasi yang tajam dan tidak ada perubahan nilai tengah. Melalui plot *ACF* dan *PACF* tersebut dapat telah dapat diidentifikasi order model *ARIMA* yang sesuai untuk data kelembaban udara. Plot *ACF* mengidentifikasi bentuk *MA*(1) untuk pola musimannya hal itu dikarenakan pada lag 12 keluar dari garis signifikan dan jika dilihat dari plot *PACF* ada pula kemungkinan mengandung pola *AR*(1) untuk musimannya. Selain itu setelah lag kedua pada plot *ACF* nampak menurun dan *PACF* memperlihatkan adanya penurunan setelah lag kedua maka dapat diduga terdapat model *AR* (2) untuk pola non-musiman. Menurut identifikasi tersebut dapat diduga order model *ARIMA* untuk kelembaban udara adalah $(2,0,0)(1,1,0)^{12}$ atau $(2,0,0)(0,1,1)^{12}$. Selanjutnya adalah identifikasi untuk deret input tekanan udara.




Gambar 3.8 Plot *Time Series* Data Tekanan Udara




Gambar 3.9 Plot ACF dan PACF Data Tekanan Udara Menunjukkan Data Belum Stasioner dalam Rata-rata dan Varians

Deret input tekanan udara pada plot *time series* dan ACF gambar di atas jelas menunjukkan data belum stasioner baik dalam rata-rata maupun dalam varians hal itu dikarenakan masih adanya fluktuasi yang tajam pada plot *time series*, dan plot ACF pun jelas memperlihatkan adanya perubahan varians serta nilai tengah dari waktu ke waktu. Data tekanan udara ini juga mengandung pola musiman yang jelas ditunjukkan oleh plot ACF. Oleh karena data tersebut belum stasioner dalam rata-rata dan varians maka dilakukan pembeda. Pembeda dua belas dilakukan karena data mengandung pola musiman. Berikut adalah plot ACF dan PACF untuk data tekanan udara setelah dilakukan pembeda duabelas.

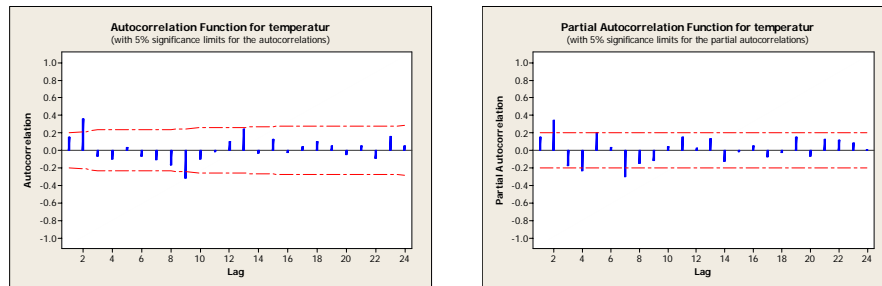


Gambar 3.10 Plot ACF dan PACF Data Tekanan Udara Setelah Dilakukan Pembeda Duabelas ($d = 12$)

Setelah dilakukan pembeda duabelas deret input untuk data tekanan udara telah stasioner dalam rata-rata dan sudah tidak terlihat lagi adanya fluktuasi data, walaupun masih ada lag yang keluar dari garis signifikan namun sudah lebih stasioner sehingga dapat diidentifikasi order model *ARIMA* untuk data tekanan udara. Pada plot *ACF* terlihat bahwa lag mengalami penurunan dan pada lag pertama plot *PACF* keluar dari garis signifikan yang mengidentifikasikan bentuk *AR(1)* untuk pola non-musiman, namun dapat juga diduga model *ARMA(1,1)* non-musiman sebab selain plot *ACF* yang menurun dari lag pertama, pada plot *PACF* pun terlihat mengalami penurunan dari lag pertama walaupun setelah lag kedua pada lag ketiga nilai autokorelasi parsial turun sampai nol. Selain itu pola musiman terlihat pada plot *ACF* yang mengidentifikasikan bentuk *MA(1)*. Dugaan order model *ARIMA* untuk data tekanan udara adalah $(1,0,1)(0,1,1)^{12}$ atau $(1,0,0)(0,1,1)^{12}$. Selanjutnya adalah identifikasi untuk deret input temperatur.

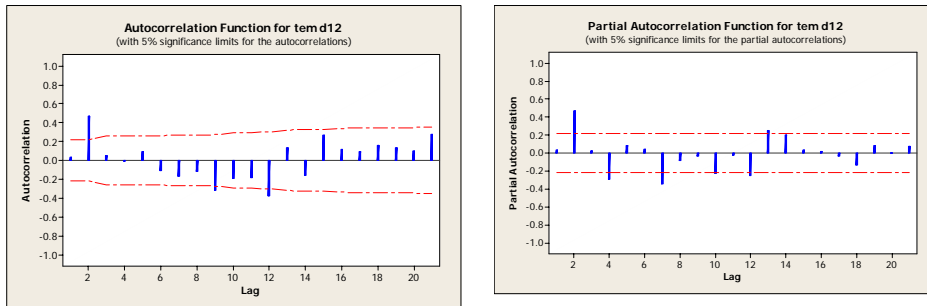


Gambar 3.11 Plot *Time Series* Data Temperatur




Gambar 3.12 Plot ACF dan PACF Data Temperatur Menunjukkan Data Belum Stasioner dalam Rata-rata

Deret input temperatur pada plot *time series* dan ACF mengidentifikasi bahwa data belum stasioner dalam rata-rata. Hal itu terlihat masih adanya perubahan nilai tengah pada plot *time series* akan tetapi data telah stasioner dalam varians hal itu terlihat bahwa tidak adanya perubahan varians dalam plot *time series*. Bila dilihat dari plot ACF dan PACF gambar 3.12 pola musiman tidak begitu nampak. Lag pada plot ACF yang signifikan pada garis putus-putus adalah lag 2, 9 dan 13. Walaupun tidak begitu menampakkan pola musiman yang jelas data dapat diduga mengandung pengaruh musiman tahunan. Untuk menstasionerkan data dalam rata-rata dapat dilakukan pembedaan. Oleh karena diduga ada pengaruh musiman tahunan maka dilakukan pembeda duabelas. Berikut plot ACF dan PACF data temperatur setelah dilakukan pembeda duabelas.

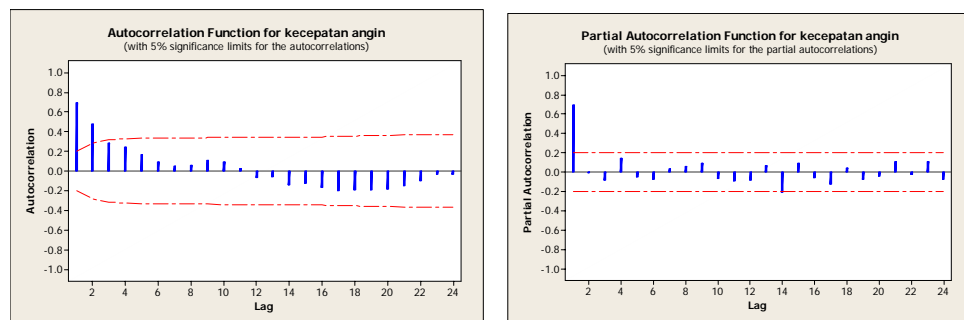


**Gambar 3.13 Plot ACF dan PACF Data Temperatur Setelah Dilakukan
Pembeda Duabelas ($d = 12$)**

Pembeda duabelas ini menyebabkan deret input untuk data temperatur telah menjadi lebih baik walaupun ada beberapa lag yang masih keluar dari garis signifikan. Melalui plot tersebut telah dapat diidentifikasi order model *ARIMA* yang sesuai untuk data temperatur. Pada plot *ACF* lag kedua keluar dari garis putus-putus begitu pula pada plot *PACF*-nya sehingga diduga model untuk data temperatur terdapat model *MA*(2) untuk non-musimannya. Bila dilihat dari plot *ACF* pada lag 12 yang bernilai negatif dan keluar dari garis signifikan sedangkan lag 13 yang bernilai positif kemudian lag 12 pada plot *PACF* turun ke bawah dan signifikan pada garis putus-putus lalu lag 13 bernilai positif maka diduga model untuk data temperatur juga terdapat model *AR*(2) untuk musiman. Kemungkinan order model *ARIMA* untuk data input temperatur adalah $(0,0,2)(2,1,0)$. Selanjutnya adalah mengidentifikasi untuk deret input kecepatan angin.




Gambar 3.14 Plot *Time Series* Data Kecepatan Angin



Gambar 3.15 Plot *ACF* dan *PACF* Data Kecepatan Angin Menunjukkan Data Stasioner dalam Rata-rata

Deret input kecepatan pada plot *ACF* dan *PACF* gambar 3.15 menunjukkan data telah stasioner dalam rata-rata. Melalui plot *ACF* dan *PACF* telah dapat diidentifikasi order model *ARIMA*-nya. Akan tetapi dalam pemodelan model fungsi transfer ini untuk mendapatkan nilai estimasi yang sesuai dengan model dan memenuhi *white noise* maka perlu disamakan banyak deretnya. Oleh sebab itu, perlu dilakukan pembeda duabelas agar deret input kecepatan angin dapat masuk dalam model fungsi transfer.



**Gambar 3.16 Plot ACF dan PACF Data Kecepatan Angin Setelah
Dilakukan Pembeda Duabelas ($d = 12$)**

Setelah dilakukan pembeda duabelas didapatkan plot *ACF* dan *PACF* yang disajikan pada gambar 3.16. Walaupun masih ada lag yang keluar dari garis signifikan akan tetapi dari plot data tersebut telah dapat untuk mengidentifikasi order model *ARIMA* yang sesuai dengan data kecepatan angin. Melihat plot *ACF* yang menurun samapi nol setelah lag kedua atau ketiga dan plot *PACF* pada lag pertama signifikan dengan garis putus-putus dapat diduga kemungkinan model untuk data kecepatan angin adalah *AR*(1) untuk non-musimannya. Sedangkan untuk pola musimannya plot *ACF* memperlihatkan pada lag 12 signifikan dengan garis tersebut sehingga diduga terdapat model *MA*(1). Kemungkinan order model *ARIMA* yang cocok untuk deret input kecepatan angin adalah $(1,0,0)(0,1,1)^{12}$. Setelah proses identifikasi deret input dan output selesai maka tahap selanjutnya adalah pemutihan deret input.

Sebelum melangkah ketahap selanjutnya yakni pemutihan deret input maka perlu dilakukan menetapkan model *ARIMA* yang sesuai terlebih dahulu. Pada tahap identifikasi telah dilakukan pendugaan order model *ARIMA* untuk masing-masing

deret input maka selanjutnya perlu dipilih model mana yang terbaik dengan melihat nilai *p-value* apakah parameter signifikan dan memilih nilai *AIC* yang terkecil apabila ada dugaan model lain yang sesuai. Berikut hasil estimasi parameter model *ARIMA* untuk masing-masing deret input. Pertama adalah estimasi parameter untuk deret input kelembaban udara.

Tabel 3.4 Estimasi Parameter, Uji Signifikansi dan Nilai *AIC* Model *ARIMA* untuk Input Kelembaban Udara.

Model <i>ARIMA</i>	Estimasi Parameter	t-value	p-value	<i>AIC</i>
$(2,0,0)(0,1,1)^{12}$	$\phi_1 = 0,25820$	2,39	0,0190	474,8991
	$\phi_2 = 0,25266$	2,33	0,0225	
	$\Theta_1 = 0,90054$	10,84	< 0,0001	
$(2,0,0)(1,1,0)^{12}$	$\phi_1 = 0,22678$	2,07	0,0412	490,5789
	$\phi_2 = 0,21601$	1,93	0,0569	
	$\Phi_1 = -0,4134$	-3,79	0,0003	

Untuk mengetahui apakah estimasi parameter signifikan dalam model maka dapat diuji dengan hipotesis sebagai berikut:

1. Hipotesis

Ho : Estimasi parameter $\phi_1, \phi_2, \Theta_1, \Phi_1$ tidak signifikan dalam model

Ho : Estimasi parameter $\phi_1, \phi_2, \Theta_1, \Phi_1$ signifikan dalam model

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji

$$t_{hitung} = \frac{estimator}{SE(estimator)}$$

4. Kriteria keputusan tolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2}, df}$ atau $p-value < 0,05$.

5. Perhitungan berdasarkan tabel 3.4

6. Kesimpulan

Berdasarkan tabel 3.4 keputusannya adalah H_0 ditolak karena semua parameter pada model $ARIMA(2,0,0)(0,1,1)^{12}$ mempunyai nilai $p-value$ yang kurang dari $\alpha = 0,05$ atau nilai $|t_{hitung}| > t_{\frac{\alpha}{2}, df}$ sehingga parameter pada $ARIMA(2,0,0)(0,1,1)^{12}$ signifikan dan dapat dimasukkan ke dalam model. Pada model $ARIMA(2,0,0)(1,1,0)^{12}$ terdapat parameter yang tidak signifikan. Bila dilihat dari nilai AIC model $ARIMA(2,0,0)(0,1,1)^{12}$ lebih kecil daripada model $ARIMA(2,0,0)(1,1,0)^{12}$. Oleh karena itu keputusannya adalah model $ARIMA(2,0,0)(0,1,1)^{12}$ merupakan model terbaik.

Setelah estimasi parameter selesai tahap selanjutnya adalah diagnostik model untuk mengetahui kesesuaian model yakni residual α_t memenuhi asumsi *white noise*. Berikut hipotesis yang digunakan untuk mengetahui apakah autokorelasi residualnya berbeda nyata dari nol.

1. Hipotesis

$H_0 : \rho_1 = \dots = \rho_k = 0$ (autokorelasi residualnya tidak signifikan)

$H_1 : \exists \rho_i \neq 0$ (autokorelasi residualnya signifikan)

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji Q = $n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k}$

4. Kriteria keputusan tolak H_0 jika $Q \geq \chi_{\alpha, df}^2$ atau p-value $\leq \alpha$

5. Perhitungan

Tabel 3.5 merupakan hasil perhitungan autokorelasi residual yang dikerjakan dengan program SAS

Tabel 3.5 Autocorrelation Check of Residuals Model

***ARIMA(2,0,0)(0,1,1)*¹² untuk Input Kelembaban Udara**

To lag	<i>Chi-Square</i>	df	$\chi_{\alpha, df}^2$	p-value
6	0,71	3	7,81	0,8716
12	3,67	9	16,92	0,9318
18	8,72	15	25,00	0,8919
24	12,03	21	36,42	0,9387

6. Kesimpulan

Berdasarkan tabel 3.5 terlihat bahwa autokorelasi residual model *ARIMA(2,0,0)(0,1,1)*¹² menunjukkan nilai p-value yang lebih dari alpha 0,05 atau nilai Q untuk semua lag kurang dari nilai $\chi_{\alpha, df}^2$. Keputusannya adalah H_0 diterima yang artinya autokorelasi residual tidak signifikan atau tidak terdapat korelasi antarlag. Oleh sebab itu dapat disimpulkan bahwa model *ARIMA(2,0,0)(0,1,1)*¹² cocok digunakan karena memenuhi asumsi *white noise*.

Selanjutnya adalah estimasi parameter dan diagnostik deret input tekanan udara.

Tabel 3.6 Estimasi Parameter, Uji Signifikansi dan Nilai *AIC* Model *ARIMA* untuk Input Tekanan Udara.

Model <i>ARIMA</i>	Estimasi Parameter	t-value	p-value	<i>AIC</i>
$(1,0,1)(0,1,1)^{12}$	$\phi_1 = 0,78800$	5,75	< 0,0001	218,407
	$\theta_1 = 0,47137$	2,39	0,0190	
	$\Theta_1 = 0,64816$	6,95	< 0,0001	
$(1,0,0)(0,1,1)^{12}$	$\phi_1 = 0,40552$	3,97	0,0002	221,156
	$\Theta_1 = 0,65996$	7,05	<0,0001	

Berikut adalah uji hipotesis untuk mengetahui signifikansi estimasi parameternya:

1. Hipotesis

H_0 : Estimasi parameter $\phi_1, \theta_1, \Theta_1$ tidak signifikan dalam model

H_a : Estimasi parameter $\phi_1, \theta_1, \Theta_1$ signifikan dalam model

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji

$$t_{hitung} = \frac{\text{estimator}}{SE(\text{estimator})}$$

4. Kriteria keputusan tolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2}, df}$ atau $p\text{-value} < 0,05$.

5. Perhitungan ada pada tabel 3.6

6. Kesimpulan

Berdasarkan tabel 3.6 semua parameter pada model $ARIMA(1,0,1)(0,1,1)^{12}$ mempunyai nilai $p\text{-value}$ kurang dari $\alpha = 0,05$ atau nilai $|t_{hit}| > t_{\frac{\alpha}{2}, df}$ maka H_0 ditolak. Ini artinya parameter pada model $ARIMA(1,0,1)(0,1,1)^{12}$ signifikan sehingga parameter dapat dimasukkan dalam model. Selain itu juga karena model $ARIMA(1,0,1)(0,1,1)^{12}$ memiliki nilai AIC yang lebih kecil daripada model $ARIMA(1,0,0)(0,1,1)^{12}$. Oleh karena itu dapat disimpulkan bahwa model $ARIMA(1,0,1)(0,1,1)^{12}$ cocok digunakan.

Untuk memeriksa apakah autokorelasi residualnya berbeda nyata dari nol atau tidak maka dilakukan uji hipotesis sebagai berikut.

1. Hipotesis

$H_0 : \rho_1 = \dots = \rho_k = 0$ (autokorelasi residualnya tidak signifikan)

$H_1 : \exists \rho_i \neq 0$ (autokorelasi residualnya signifikan)

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k}$

4. Kriteria keputusan tolak H_0 adalah jika $Q \geq \chi_{\alpha, df}^2$ atau $p\text{-value} \leq \alpha$

5. Perhitungan

Berikut ini adalah tabel hasil perhitungan autokorelasi residual pada model $ARIMA(1,0,1)(0,1,1)^{12}$

Tabel 3.7 Autocorrelation Check of Residuals Model **$ARIMA(1,0,1)(0,1,1)^{12}$ untuk Input Tekanan Udara**

To lag	<i>Chi-Square</i>	df	$\chi^2_{\alpha,df}$	p-value
6	7,51	3	7,81	0,0572
12	11,27	9	16,92	0,2573
18	12,92	15	25,00	0,6082
24	20,64	21	32,67	0,4813

6. Kesimpulan

Berdasarkan tabel 3.7 menunjukkan bahwa nilai *p-value* untuk semua lag lebih dari 0,05 sehingga dapat disimpulkan bahwa H_0 diterima berarti autokorelasi residualnya tidak signifikan atau tidak terdapat korelasi antarlag maka residual memenuhi asumsi *white noise*. Jadi model $ARIMA(1,0,1)(0,1,1)^{12}$ layak digunakan.

Selanjutnya estimasi parameter dan diagnostic untuk deret input temperatur.

Tabel 3.8 Estimasi Parameter dan Uji Signifikansi Model $ARIMA(0,0,2)(2,1,0)^{12}$ untuk Input Temperatur.

Model <i>ARIMA</i>	Estimasi Parameter	t-value	p-value
$(0,0,2)(2,0,0)^{12}$	$\theta_2 = -0,62572$	-7,21	< 0,0001
	$\Phi_1 = -0,50689$	-4,49	< 0,0001
	$\Phi_2 = -0,49954$	-4,17	< 0,0001

Untuk mengetahui apakah estimasi parameter signifikan dalam model maka dapat diuji dengan hipotesis sebagai berikut:

1. Hipotesis

H_0 : Estimasi parameter θ_2, Φ_1, Φ_2 tidak signifikan dalam model

H_a : Estimasi parameter θ_2, Φ_1, Φ_2 signifikan dalam model

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji

$$t_{hitung} = \frac{estimator}{SE(estimator)}$$

4. Kriteria keputusan tolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2}, df}$ atau $p-value < 0,05$.

5. Perhitungan ada pada tabel 3.8

6. Kesimpulan

Berdasarkan tabel 3.8 H_0 ditolak sebab parameter model $ARIMA(0,0,2)(2,1,0)^{12}$ mempunyai $p-value$ yang kurang dari $\alpha = 0,05$. Oleh karena itu dan disimpulkan bahwa parameter signifikan dan dapat dimasukkan dalam model. Sehingga model $ARIMA(0,0,2)(2,1,0)^{12}$ merupakan model terbaik.

Setelah estimasi parameter selesai tahap selanjutnya adalah diagnostik model untuk mengetahui kesesuaian model yakni residual α_t memenuhi asumsi *white noise*. Berikut adalah uji hipotesis untuk mengetahui apakah autokorelasi residualnya berbeda nyata dari nol.

1. Hipotesis

$H_0 : \rho_1 = \dots = \rho_k = 0$ (autokorelasi residualnya tidak signifikan)

$H_1 : \exists \rho_i \neq 0$ (autokorelasi residualnya signifikan)

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k}$

4. Kriteria keputusan untuk menolak H_0 jika $Q \geq \chi_{\alpha, df}^2$ atau p-value $\leq \alpha$

5. Perhitungan

Tabel 3.9 merupakan hasil perhitungan autokorelasi residual pada model $ARIMA(0,0,2)(2,1,0)^{12}$

Tabel 3.9 Autocorrelation Check of Residuals Model

$ARIMA(0,0,2)(2,1,0)^{12}$ untuk Input Temperatur.

To lag	<i>Chi-Square</i>	df	$\chi_{\alpha, df}^2$	p-value
6	4,23	3	7,81	0,2374
12	10,45	9	16,92	0,3153
18	18,19	15	25,00	0,2530
24	23,68	21	32,67	0,3086

6. Kesimpulan

Berdasarkan tabel 3.9 menunjukkan bahwa nilai p-value untuk semua lag lebih dari 0,05 sehingga dapat disimpulkan bahwa H_0 diterima artinya autokorelasi residualnya tidak signifikan atau tidak terdapat korelasi antarlag maka residual telah memenuhi asumsi *white noise*. Oleh karena itu model $ARIMA(0,0,2)(2,1,0)^{12}$ cocok digunakan.

Terakhir adalah estimasi parameter dan diagnostic deret input kecepatan angin.

Tabel 3.10 Estimasi Parameter dan Uji Signifikansi Model

$ARIMA(1,0,0) (0,1,1)^{12}$ untuk Input Kecepatan Angin.

Model $ARIMA$	Estimasi Parameter	t-value	p-value
$(1,0,0)(0,1,1)^{12}$	$\phi_1 = 0,79874$	11,27	< 0,0001
	$\Theta_1 = 0,94537$	11,97	< 0,0001

Berikut adalah uji hipotesis untuk mengetahui signifikansi estimasi parameternya:

1. Hipotesis

H_0 : Estimasi parameter ϕ_1 , Θ_1 tidak signifikan dalam model

H_a : Estimasi parameter ϕ_1 , Θ_1 signifikan dalam model

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji
$$t_{hitung} = \frac{estimator}{SE(estimator)}$$

4. Kriteria keputusan tolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2}, df}$ atau $p-value < 0,05$.

5. Perhitungan ada pada tabel 3.10

6. Kesimpulan

Berdasarkan tabel 3.10 $p-value$ untuk semua parameter pada model $ARIMA(1,0,0)(0,1,1)^{12}$ kurang dari 0,05 sehingga H_0 ditolak yang artinya parameter signifikan dalam model. Jadi model tersebut merupakan model terbaik.

Untuk mengetahui bahwa residual α_t memenuhi asumsi *white noise* maka dapat dilakukan uji dengan menggunakan statistik Q Box-Pierce. Berikut adalah uji hipotesis untuk mengetahui apakah autokorelasi residualnya berbeda nyata dari nol.

1. Hipotesis

$H_0 : \rho_1 = \dots = \rho_k = 0$ (autokorelasi residualnya tidak signifikan)

$H_1 : \exists \rho_i \neq 0$ (autokorelasi residualnya signifikan)

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k}$

4. Kriteria keputusan tolak H_0 jika $Q \geq \chi_{\alpha, df}^2$ atau p-value $\leq \alpha$

5. Perhitungan nilai autokorelasi untuk memeriksa residual pada model dikerjakan dengan program SAS

Tabel 3.11 Autocorrelation Check of Residuals Model

ARIMA(1,0,0) (0,1,1)¹² untuk Kecepatan Angin.

To lag	<i>Chi-Square</i>	df	$\chi_{\alpha, df}^2$	p-value
6	5,57	4	9,49	0,2335
12	10,47	10	18,31	0,4006
18	15,92	16	26,30	0,4588
24	18,78	22	33,92	0,6589

6. Kesimpulan

Berdasarkan tabel 3.11 menunjukkan bahwa nilai *p-value* untuk semua lag lebih dari 0,05 sehingga dapat disimpulkan bahwa terima H_0 artinya autokorelasi residualnya tidak signifikan atau tidak terdapat korelasi antarlag maka residual telah memenuhi asumsi *white noise*. Jadi model $ARIMA(1,0,0)(0,1,1)^{12}$ layak digunakan.

1.2 Pemutihan deret input

Setelah didapatkan model $ARIMA$ untuk masing-masing deret input maka tahap pemutihan deret input dapat ditentukan. Berikut merupakan pemutihan deret input:

a. Pemutihan deret input kelembaban udara dengan model $ARIMA(2,0,0)(0,1,1)^{12}$

$$(1 - \phi_1 B - \phi_2 B^2)(1 - B^{12})x_{1t} = (1 - \Theta_1 B^{12})\alpha_{1t} \quad (3.37)$$

$$(1 - B^{12} - \phi_1 B + \phi_1 B^{13} - \phi_2 B^2 + \phi_2 B^{14})x_{1t} = (1 - \Theta_1 B^{12})\alpha_{1t}$$

$$x_{1t} - x_{1t-12} - \phi_1 x_{1t-1} + \phi_1 x_{1t-13} - \phi_2 x_{1t-2} + \phi_2 x_{1t-14} = \alpha_{1t} - \Theta_1 \alpha_{1t-12}$$

$$\alpha_{1t} = x_{1t} - x_{1t-12} - \phi_1 x_{1t-1} + \phi_1 x_{1t-13} - \phi_2 x_{1t-2} + \phi_2 x_{1t-14} + \Theta_1 \alpha_{1t-12}$$

dengan $\phi_1 = 0,25820$, $\phi_2 = 0,25266$, $\Theta_1 = 0,90054$ dan tetapkan $\alpha_{1(1-14)} = 0$

sehingga deret α_{1t} menjadi sebagai berikut

$$\alpha_{1t} = x_{1t} - x_{1t-12} - 0,2582x_{1t-1} + 0,2582x_{1t-13} - 0,25266x_{1t-2} + 0,25266x_{1t-14} + 0,90054\alpha_{1t-12}$$

hasilnya disajikan pada lampiran 2.

b. Pemutihan deret input tekanan udara dengan model $ARIMA(1,0,1)(0,1,1)^{12}$

$$(1 - \phi_1 B)(1 - B^{12})x_{2t} = (1 - \theta_1 B)(1 - \Theta_1 B^{12})\alpha_{2t} \quad (3.38)$$

$$(1 - B^{12} - \phi_1 B + \phi_1 B^{13})x_{2t} = (1 - \Theta_1 B^{12} - \theta_1 B + \theta_1 \Theta_1 B^{13})\alpha_{2t}$$

$$x_{2t} - x_{2t-12} - \phi_1 x_{2t-1} + \phi_1 x_{2t-13} = \alpha_{2t} - \Theta_1 \alpha_{2t-12} - \theta_1 \alpha_{2t-1} + \theta_1 \Theta_1 \alpha_{2t-13}$$

$$\alpha_{2t} = x_{2t} - x_{2t-12} - \phi_1 x_{2t-1} + \phi_1 x_{2t-13} + \Theta_1 \alpha_{2t-12} + \theta_1 \alpha_{2t-1} - \theta_1 \Theta_1 \alpha_{2t-13}$$

dengan $\phi_1 = 0,78800$, $\theta_1 = 0,47137$, $\Theta_1 = 0,64816$ dan tetapkan $\alpha_{2(1-13)} = 0$

sehingga deret α_{2t} menjadi sebagai berikut

$$\alpha_{2t} = x_{2t} - x_{2t-12} - 0,78800x_{2t-1} + 0,78800x_{2t-13} + 0,64816\alpha_{2t-12} + 0,47137\alpha_{2t-1} - 0,30552\alpha_{2t-13}$$

hasilnya disajikan pada lampiran 2.

c. Pemutihan deret input temperatur dengan model $ARIMA(0,0,2)(2,1,0)^{12}$

$$(1 - \Phi_1 B^{12} - \Phi_2 B^{24})(1 - B^{12})x_{3t} = (1 - \theta_2 B^2)\alpha_{3t} \quad (3.39)$$

$$(1 - \Phi_1 B^{12} - \Phi_2 B^{24} - B^{12} + \Phi_1 B^{24} + \Phi_2 B^{36})x_{3t} = (1 - \theta_2 B^2)\alpha_{3t}$$

$$x_{3t} - \Phi_1 x_{3t-12} - \Phi_2 x_{3t-24} - x_{3t-12} + \Phi_1 x_{3t-24} + \Phi_2 x_{3t-36} = \alpha_{3t} - \theta_2 \alpha_{3t-2}$$

$$\alpha_{3t} = x_{3t} - \Phi_1 x_{3t-12} - \Phi_2 x_{3t-24} - x_{3t-12} + \Phi_1 x_{3t-24} + \Phi_2 x_{3t-36} + \theta_2 \alpha_{3t-2}$$

dengan $\Phi_1 = -0,50689$, $\Phi_2 = -0,49954$, $\theta_2 = -0,62572$ dan tetapkan $\alpha_{3(1-36)} = 0$

sehingga deret α_{3t} menjadi sebagai berikut

$$\alpha_{3t} = x_{3t} + 0,50689x_{3t-12} + 0,49954x_{3t-24} - x_{3t-12} - 0,50689x_{3t-24} - 0,49954x_{3t-36} - 0,62572\alpha_{3t-2}$$

hasilnya disajikan pada lampiran 2.

d. Pemutihan deret input kecepatan angin dengan model $ARIMA(1,0,0)(0,1,1)^{12}$

$$(1 - \phi_1 B)(1 - B^{12})x_{4t} = (1 - \Theta_1 B^{12})\alpha_{4t} \quad (3.40)$$

$$(1 - \phi_1 B - B^{12} + \phi_1 B^{13})x_{4t} = (1 - \Theta_1 B^{12})\alpha_{4t}$$

$$x_{4t} - \phi_1 x_{4t-1} - x_{4t-12} + \phi_1 x_{4t-13} = \alpha_{4t} - \Theta_1 \alpha_{4t-12}$$

$$\alpha_{4t} = x_{4t} - \phi_1 x_{4t-1} - x_{4t-12} + \phi_1 x_{4t-13} + \Theta_1 \alpha_{4t-12}$$

dengan $\phi_1 = 0,79874$, $\Theta_1 = 0,94537$ dan tetapkan $\alpha_{4(1-13)} = 0$ sehingga deret

α_{4t} menjadi sebagai berikut

$$\alpha_{4t} = x_{4t} - 0,79874x_{4t-1} - x_{4t-12} + 0,79874x_{4t-13} + 0,94537\alpha_{4t-12}$$

hasilnya disajikan pada lampiran 2.

1.3 "Pemutihan" deret output

Setelah pada tahap pemutihan deret input selesai maka selanjutnya adalah “pemutihan” deret output. Cara untuk melakukan “pemutihan” deret output yakni menggunakan persamaan yang ada pada masing-masing deret input dan mengganti x_{it} menjadi y_{it} serta mengganti α_{it} menjadi β_{it} . Berikut merupakan proses “pemutihan” deret output

a. “Pemutihan” deret output untuk kelembaban udara dengan model

$$ARIMA(2,0,0)(0,1,1)^{12}$$

$$(1 - \phi_1 B - \phi_2 B^2)(1 - B^{12})y_{1t} = (1 - \Theta_1 B^{12})\beta_{1t} \quad (3.41)$$

$$(1 - B^{12} - \phi_1 B + \phi_1 B^{13} - \phi_2 B^2 + \phi_2 B^{14})y_{1t} = (1 - \Theta_1 B^{12})\beta_{1t}$$

$$y_{1t} - y_{1t-12} - \phi_1 y_{1t-1} + \phi_1 y_{1t-13} - \phi_2 y_{1t-2} + \phi_2 y_{1t-14} = \beta_{1t} - \Theta_1 \beta_{1t-12}$$

$$\beta_{1t} = y_{1t} - y_{1t-12} - \phi_1 y_{1t-1} + \phi_1 y_{1t-13} - \phi_2 y_{1t-2} + \phi_2 y_{1t-14} + \Theta_1 \beta_{1t-12}$$

dengan $\phi_1 = 0,25820$, $\phi_2 = 0,25266$, $\Theta_1 = 0,90054$ dan tetapkan $\beta_{1(1-14)} = 0$

sehingga deret β_{1t} menjadi sebagai berikut

$$\beta_{1t} = y_{1t} - y_{1t-12} - 0,2582y_{1t-1} + 0,2582y_{1t-13} - 0,25266y_{1t-2} + 0,25266y_{1t-14} + 0,90054\beta_{1t-12}$$

hasilnya disajikan pada lampiran 2.

b. “Pemutihan” deret output untuk tekanan udara dengan model

$$ARIMA(1,0,1)(0,1,1)^{12}$$

$$(1 - \phi_1 B)(1 - B^{12})y_{2t} = (1 - \theta_1 B)(1 - \Theta_1 B^{12})\beta_{2t} \quad (3.42)$$

$$(1 - B^{12} - \phi_1 B + \phi_1 B^{13})y_{2t} = (1 - \Theta_1 B^{12} - \theta_1 B + \theta_1 \Theta_1 B^{13})\beta_{2t}$$

$$y_{2t} - y_{2t-12} - \phi_1 y_{2t-1} + \phi_1 y_{2t-13} = \beta_{2t} - \Theta_1 \beta_{2t-12} - \theta_1 \beta_{2t-1} + \theta_1 \Theta_1 \beta_{2t-13}$$

$$\beta_{2t} = y_{2t} - y_{2t-12} - \phi_1 y_{2t-1} + \phi_1 y_{2t-13} + \Theta_1 \beta_{2t-12} + \theta_1 \beta_{2t-1} - \theta_1 \Theta_1 \beta_{2t-13}$$

dengan $\phi_1 = 0,78800$, $\theta_1 = 0,47137$, $\Theta_1 = 0,64816$ dan tetapkan $\beta_{2(1-13)} = 0$

sehingga deret β_{2t} menjadi sebagai berikut

$$\beta_{2t} = y_{2t} - y_{2t-12} - 0,78800 y_{2t-1} + 0,78800 y_{2t-13} + 0,64816 \beta_{2t-12} + 0,47137 \beta_{2t-1} - 0,30552 \beta_{2t-13}$$

hasilnya disajikan selengkapnya pada lampiran 2.

c. “Pemutihan” deret output untuk temperatur dengan model

$$ARIMA(0,0,2)(2,1,0)^{12}$$

$$(1 - \Phi_1 B^{12} - \Phi_2 B^{24})(1 - B^{12})y_{3t} = (1 - \theta_2 B^2)\beta_{3t} \quad (3.43)$$

$$(1 - \Phi_1 B^{12} - \Phi_2 B^{24} - B^{12} + \Phi_1 B^{24} + \Phi_2 B^{36})y_{3t} = (1 - \theta_2 B^2)\beta_{3t}$$

$$y_{3t} - \Phi_1 y_{3t-12} - \Phi_2 y_{3t-24} - y_{3t-12} + \Phi_1 y_{3t-24} + \Phi_2 y_{3t-36} = \beta_{3t} - \theta_2 \beta_{3t-2}$$

$$\beta_{3t} = y_{3t} - \Phi_1 y_{3t-12} - \Phi_2 y_{3t-24} - y_{3t-12} + \Phi_1 y_{3t-24} + \Phi_2 y_{3t-36} + \theta_2 \beta_{3t-2}$$

dengan $\Phi_1 = -0,50689$ $\Phi_2 = -0,49954$, $\theta_2 = -0,62572$ dan tetapkan $\beta_{3(1-36)} = 0$

sehingga deret β_{3t} menjadi sebagai berikut

$$\beta_{3t} = y_{3t} + 0,50689y_{3t-12} + 0,49954y_{3t-24} - y_{3t-12} - 0,50689y_{3t-24} - 0,49954y_{3t-36} - 0,62572\beta_{3t-2}$$

hasilnya disajikan pada lampiran 2.

d. Pemutihan deret output untuk kecepatan angin dengan model

$$ARIMA(1,0,0)(0,1,1)^{12}$$

$$(1 - \phi_1 B)(1 - B^{12})y_{4t} = (1 - \Theta_1 B^{12})\beta_{4t} \quad (3.44)$$

$$(1 - \phi_1 B - B^{12} + \phi_1 B^{13})y_{4t} = (1 - \Theta_1 B^{12})\beta_{4t}$$

$$y_{4t} - \phi_1 y_{4t-1} - y_{4t-12} + \phi_1 y_{4t-13} = \beta_{4t} - \Theta_1 \beta_{4t-12}$$

$$\beta_{4t} = y_{4t} - \phi_1 y_{4t-1} - y_{4t-12} + \phi_1 y_{4t-13} + \Theta_1 \beta_{4t-12}$$

dengan $\phi_1 = 0,79874$, $\Theta_1 = 0,94537$ dan tetapkan $\beta_{4(1-13)} = 0$ sehingga deret β_{4t}

menjadi sebagai berikut

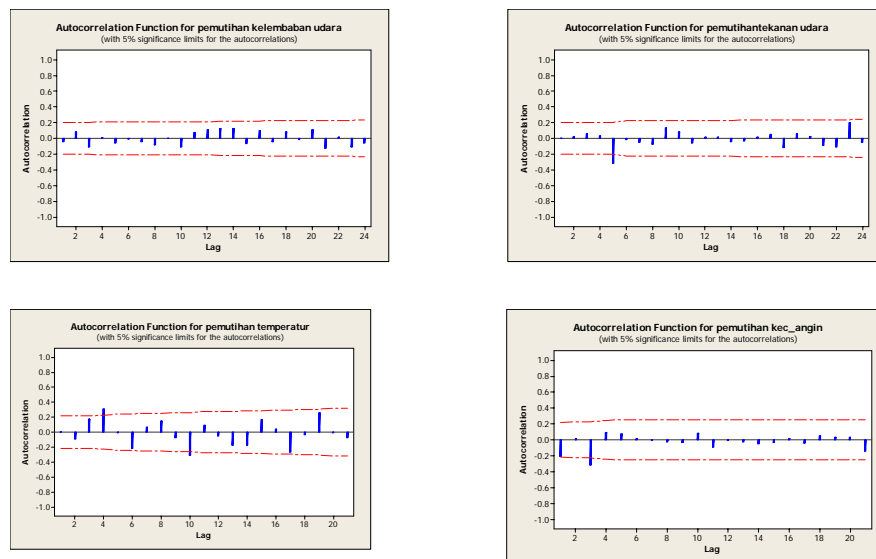
$$\beta_{4t} = y_{4t} - 0,79874y_{4t-1} - y_{4t-12} + 0,79874y_{4t-13} + 0,94537\beta_{4t-12}$$

hasilnya disajikan pada lampiran 2.

Tahap selanjutnya setelah pemutihan deret input dan output selesai adalah pengecekan korelasi silang dan autokorelasi deret input dan output yang telah diputihkan.

1.4 Perhitungan korelasi silang dan autokorelasi deret input dan deret output yang telah diputihkan

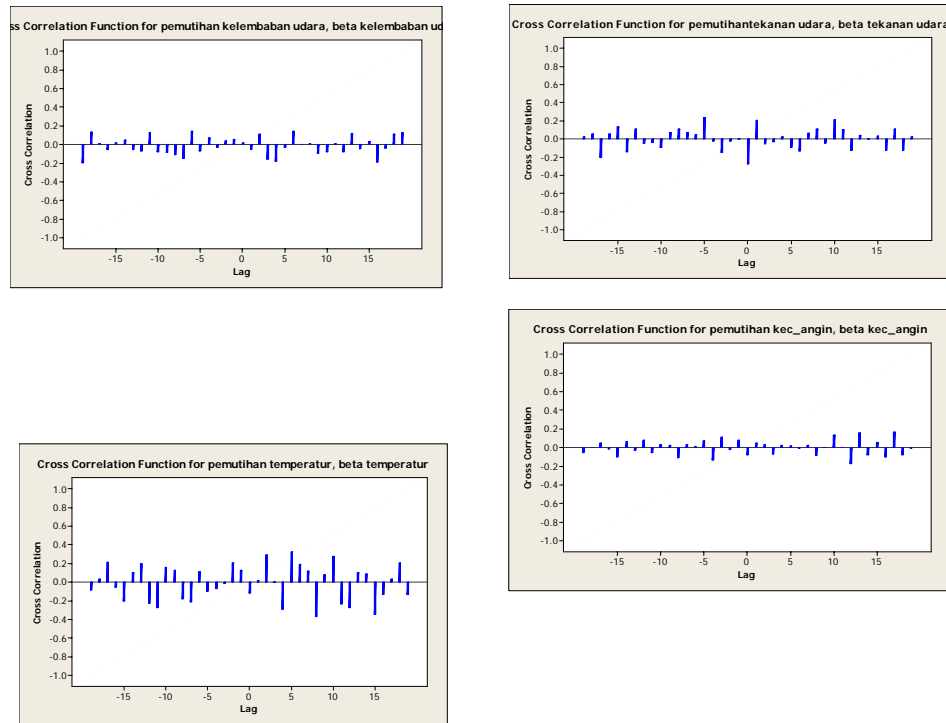
Pada tahap ini perhitungan korelasi silang dan autokorelasi dilakukan pada masing-masing deret input dan deret output yang telah diputihkan tujuannya adalah untuk mengetahui adakah hubungan dari waktu ke waktu yang mempengaruhi deret tersebut. Sebelum dilakukan korelasi silang antarderet input dan output yang perlu diselidiki adalah autokorelasi dari masing-masing deret input. Berikut adalah hasil autokorelasi deret input yang telah diputihkan.



Gambar 3.17 Plot ACF masing-masing deret input yang telah diputihkan

Pada gambar 3.17 memperlihatkan autokorelasi pada masing-masing deret input yang telah diputihkan. Autokorelasi pada input kelembaban udara, tekanan udara dan kecepatan angin menunjukkan pada dasarnya telah nol. Sedangkan pada deret input temperatur terlihat ada beberapa lag yang melebihi garis signifikansi, akan tetapi autokorelasi yang mendekati nol lebih banyak daripada yang tidak signifikan terhadap nol hal itu menandakan adanya penundaan sebelum deret input mempengaruhi deret output. Oleh karena deret input yang telah diputihkan pada dasarnya telah nol sehingga model *ARIMA* pada deret input dapat diterima.

Setelah autokorelasi telah sesuai maka dilakukan korelasi silang untuk masing-masing deret input terhadap deret output yang telah diputihkan. Dari korelasi silang ini diharapkan akan diperoleh hasil dimana deret input tidak mempengaruhi deret output. Apabila ada pengaruh dari beberapa bulan yang mempengaruhi bulan-bulan selanjutnya dan sesaat kemudian pengaruh tersebut tidak ada maka itu disebut penundaan yang pada langkah selanjutnya akan dijadikan sebagai penentu waktu *delay* (*b*). Berikut adalah hasil dari korelasi silang yang akan berguna untuk menentukan bobot respon impuls pada tahap selanjutnya.



**Gambar 3.18 Plot CCF Masing-masing Deret Input dan Output
yang Telah Diputihkan**

Nilai korelasi silang terdapat pada lampiran 3 yang menjadi dasar dalam penaksiran langsung bobot respon impuls. Namun sebelum ke tahap selanjutnya perlu dihitung terlebih dahulu diskripsi statistik masing-masing korelasi silang pada deret input dan output yang telah diputihkan.

Tabel 3.12 Diskripsi Statistik pada Korelasi Silang Masing-masing Deret Input dan Output

Kelembaban udara α_{1t}		Kelembaban udara β_{1t}	
Mean	-0,346	Mean	11,67
Standard Deviation	3,687	Standard Deviation	89,949
tekanan udara α_{2t}		tekanan udara β_{2t}	
Mean	-0,078	Mean	8,876
Standard Deviation	0,808	Standard Deviation	86,556
temperatur α_{3t}		temperatur β_{3t}	
Mean	-0,068	Mean	11,182
Standard Deviation	0,732	Standard Deviation	80,520
kec_angin α_{4t}		kec_angin β_{4t}	
Mean	0,187	Mean	7,766
Standard Deviation	1,096	Standard Deviation	109,438

Tabel di atas berisikan standar deviasi masing-masing variabel input dan output yang digunakan untuk penaksiran langsung bobot respon impuls.

1.5 Penaksiran langsung bobot respons impuls

Pada tahap ini untuk menghasilkan bobot respon impuls menggunakan hasil yang diperoleh dalam korelasi silang akan tetapi nilai negatif tidak digunakan dalam

penaksiran langsung bobot respons impuls ini sehingga bobot respon impuls yang diperoleh mulai dari $k = 0, 1, \dots, 19$. Rumus untuk menentukan bobot respons impuls adalah pada persamaan (3.15)

Hasil dari korelasi silang yang ada di lampiran 3 dan standar deviasi deret input dan output pada tabel 3.12 maka dengan menggunakan rumus persamaan (3.15) didapatkan hasil perhitungan bobot respons impuls fungsi transfer untuk input tunggal sebagai berikut:

Tabel 3.13 Bobot Respon Impuls yang Mengidentifikasi Fungsi Transfer

k	$v_{1(k)}$	k	$v_{2(k)}$	k	$v_{3(k)}$	k	$v_{4(k)}$
0	0.336	0	-29.595	0	-3.392	0	-8.004
1	-1.427	1	20.906	1	-2.263	1	4.460
2	2.624	2	-15.568	2	6.755	2	2.979
3	-3.862	3	1.698	3	-3.903	3	-7.220
4	-3.417	4	13.920	4	-19.222	4	2.490
5	-0.854	5	-6.237	5	17.848	5	1.203
6	3.484	6	-10.636	6	14.505	6	-1.220
7	-0.082	7	1.608	7	8.447	7	2.152
8	0.139	8	17.709	8	-11.316	8	-8.704
9	-2.361	9	-3.522	9	5.694	9	0.011
10	-1.854	10	6.532	10	10.116	10	13.254
11	0.195	11	9.503	11	-8.927	11	-0.126
12	-2.014	12	-11.701	12	0.535	12	-17.313
13	2.937	13	2.855	13	12.207	13	15.892
14	-1.074	14	-8.158	14	-10.167	14	-7.582
15	0.742	15	6.151	15	-24.182	15	5.389
16	-4.669	16	-9.588	16	-14.700	16	-10.581
17	-0.942	17	9.900	17	-0.373	17	16.303
18	2.779	18	-15.567	18	12.019	18	-7.615
19	3.048	19	6.473	19	-7.123	19	-0.569

1.6 Penetapan (r, s, b) untuk model fungsi transfer yang menghubungkan deret input dan deret output

Parameter b merupakan nilai mutlak penundaan (*delay*) sebelum deret input mempengaruhi deret output. Penentuannya adalah dengan menggunakan grafik

pada bobot respon implus atau menggunakan nilai korelasi silang yaitu pada lag yang pertama kali mempengaruhi y secara signifikan. Sedangkan penentuan s adalah dengan memperkirakan lag waktu yang memperlihatkan suatu pola yang tidak jelas dan penentuan r adalah dengan memperkirakan lag waktu yang memperlihatkan suatu pola yang jelas. Berikut merupakan perkiraan (r,s,b) untuk model fungsi transfer input tunggal.

Tabel 3.14 Estimasi penentuan (r,s,b)

Variabel input	r	s	b
Kelembaban udara (X_1)	0	0	3
Tekanan udara (X_2)	0	0	0
Temperatur (X_3)	0	0	4
Kecepatan angin (X_4)	0	0	12

Nilai r dan s pada semua variabel input bernilai nol karena pada plot korelasi silang dapat dilihat bahwa lag-lag pada korelasi silang tidak menunjukkan pola yang jelas sehingga diduga nilai yang sesuai adalah nol. Sedangkan untuk nilai tundanya dapat dilihat pada masing-masing plot korelasi silang bahwa lag pertama yang mempengaruhi secara signifikan pada kelembaban udara adalah 3 dengan nilai lag -0,14969, pada tekanan udara lag yang pertama mempengaruhi y adalah lag ke nol dengan nilai -0,24531 sehingga dapat dikatakan bahwa dari awal x telah mempengaruhi y . Lag yang pertama mempengaruhi pada deret input temperatur adalah lag keempat dengan nilai -0,19031. Terakhir kecepatan angin, keterlambatan terjadi pada lag 12 yang menandakan pada waktu-waktu sebelumnya x belum mempengaruhi y setelah pada lag 12, baru x mempengaruhi y dengan nilai

-0,22182 setelah itu tidak berpengaruh lagi. Berdasarkan tabel 3.14 model fungsi transfer input tunggal yang terbentuk adalah sebagai berikut:

Model fungsi transfer untuk kelembaban udara

$$v(B)x_{1t} = \omega_0(x_1)_{t-3} \quad (3.45)$$

$$y_{1t} = \omega_0(x_1)_{t-3} + noise \quad (3.46)$$

Model fungsi transfer untuk tekanan udara

$$v(B)x_{2t} = \omega_0(x_2)_{t-0} \quad (3.47)$$

$$y_{2t} = \omega_0(x_2)_t + noise \quad (3.48)$$

Model fungsi transfer untuk temperatur

$$v(B)x_{3t} = \omega_0(x_3)_{t-4} \quad (3.49)$$

$$y_{3t} = \omega_0(x_3)_{t-4} + noise \quad (3.50)$$

Model fungsi transfer kecepatan angin

$$v(B)x_{4t} = \omega_0(x_4)_{t-12} \quad (3.51)$$

$$y_{4t} = \omega_0(x_4)_{t-12} + noise \quad (3.52)$$

1.7 Penaksiran awal deret gangguan (n_t)

Tahap selanjutnya adalah menghitung taksiran awal komponen *noise* dari model fungsi transfer dengan menggunakan persamaan sebagai berikut:

$$n_t = y_t - v_0 x_t - v_1 x_{t-1} - v_2 x_{t-2} - \dots - v_{19} x_{t-19} \quad (3.53)$$

Masing-masing deret input dicari deret *noisenya* yang akan berguna untuk melengkapi model fungsi transfer yang terbentuk. Hasil deret *noise* selengkapnya ada pada lampiran 4

$$n_t = y_t - v_0 x_t - v_1 x_{t-1} - v_2 x_{t-2} - \dots - v_{19} x_{t-19} \quad (3.54)$$

$$(n_1)_{20} = y_{20} - v_0 x_{19} - v_1 x_{18} - v_2 x_{17} - \dots - v_{19} x_1$$

$$(n_1)_{20} = 0 - (0.336)(12) - (-1.427)(-3) - (2.426)(3) - \dots - (3.048)(-1)$$

$$= 59,24$$

$$(n_2)_{20} = 0 - (-29.59)(-2.6) - (20.90)(0.7) - (-15.56)(0.4) - \dots - (6.47)(1)$$

$$= 32,81$$

$$(n_3)_{20} = 0 - (-3.39)(3) - (-2.26)(-0.5) - (6.75)(3) - \dots - (-7.12)(0.1)$$

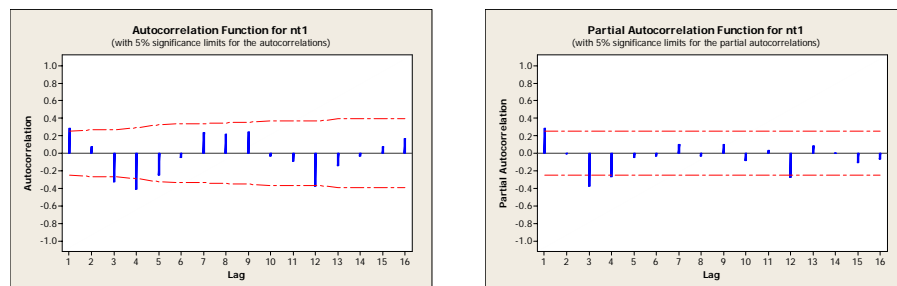
$$= 50,80$$

$$(n_4)_{20} = 0 - (-8.004)(3) - (4.46)(2) - (2.97)(2) - \dots - (-0.56)(1)$$

$$= 20,07$$


1.8 Penetapan (p_n, q_n) untuk model $ARIMA(p_n, 0, q_n)$ dari deret gangguan n_t

Penetapan nilai (p_n, q_n) ini bertujuan mencari model $ARIMA$ untuk deret *noise* caranya sama halnya yang dilakukan pada pembentukan model $ARIMA$ sebelumnya pada deret input. Berikut merupakan plot ACF dan $PACF$ untuk menentukan nilai (p_n, q_n) pada deret *noise*.



Gambar 3.19 Plot ACF dan $PACF$ pada Deret *Noise* Kelembaban Udara


Gambar 3.19 menunjukkan plot ACF dan $PACF$ deret *noise* pada kelembaban udara. Berdasarkan kedua plot tersebut dapat diidentifikasi model $ARIMA$ untuk deret noisenya. Plot ACF mengidentifikasi bentuk $MA(1)$ untuk musiman dan dari plot $PACF$ membentuk model $AR(1)$ non-musiman.



Gambar 3.20 Plot ACF dan $PACF$ pada Deret *Noise* Tekanan Udara



Pada plot ACF terlihat lag pertama keluar dari garis dan kemudian lag kedua turun samapi nol sehingga dapat diduga model $MA(1)$, sedangkan jika dilihat dari

plot *ACF* setelah lag 12 nilainya turun sampai nol didukung dengan plot *PACF* pada lag 12 keluar dari garis kemudian nilainya turun yang mengidentifikasi model *AR*(1) musiman. Sehingga dapat diduga model *ARIMA* untuk deret *noise* tekanan udara adalah $(0,0,1)(1,0,0)^{12}$.



Gambar 3.21 Plot *ACF* dan *PACF* pada Deret *Noise* Temperatur

Plot *PACF* gambar 3.29 memperlihatkan lag pertama keluar dari garis dan kemudian turun membentuk pola eksponensial dan didukung dengan lag pertama pada plot *ACF* yang keluar dari garis lalu turun yang mengidentifikasi model *AR*(1) non-musiman. Sedangkan pola musiman tidak begitu nampak namun dengan melihat plot *PACF* lag 1, 4, 11 dan 12 keluar dari garis sehingga dapat diduga ada pola musiman didalamnya. Untuk mengetahui model untuk musimannya dilihat dari plot *ACF* setelah lag 12 nilainya turun sampai nol dan plot *PACF* setelah lag 12 nilainya turun kemudian lag 14 terpotong sehingga dapat diduga ada model *MA*(1) musiman. Oleh karena itu diduga model *ARIMA* deret *noise* untuk temperature adalah $(1,0,0)(0,0,1)^{12}$.



Gambar 3.22 Plot ACF dan PACF pada Deret Noise Kecepatan Angin

Terakhir adalah menentukan model *ARIMA* untuk deret noise kecepatan angin. Plot *ACF* memperlihatkan setelah lag pertama nilainya turun dan membentuk pola gelombang sinus, sedangkan plot *PACF* pada lag pertama keluar dari garis lalu lag kedua nilainya turun. Hal ini mengidentifikasi terdapat model *MA*(1). Pada lag 12 plot *ACF* keluar dari garis putus-putus kemudian lag berikutnya nilainya turun sampai nol yang mengidentifikasi bentuk *AR*(1) untuk musimannya. Dugaan model untuk deret *noise* kecepatan angin adalah $(0,0,1)(1,0,0)^{12}$.

Untuk mengetahui apakah model-model *ARIMA* tersebut cocok digunakan maka dilakukan pemeriksaan diagnosis pada model tersebut. Berikut adalah estimasi parameter dan tabel uji *Ljung-Box* untuk mengetahui kesesuaian model yang digunakan.

Tabel 3.15 Estimasi Parameter**Masing-masing Deret Noise**

Model <i>ARIMA</i>	Parameter	P
Deret <i>noise</i> pertama $(1,0,0)(0,0,1)^{12}$	$\phi_1 = 0,24247$ $\Theta_1 = 0,63792$	0,0272 < 0,0001
Deret <i>noise</i> kedua $(0,0,1)(1,0,0)^{12}$	$\theta_1 = -0,30573$ $\Phi_1 = -0,6103$	0,0056 < 0,0001
Deret <i>noise</i> ketiga $(1,0,0)(0,0,1)^{12}$	$\phi_1 = 0,2996$ $\Theta_1 = 0,6176$	0,0058 < 0,0001
Deret <i>noise</i> keempat $(0,0,1)(1,0,0)^{12}$	$\theta_1 = -0,3050$ $\Phi_1 = -0,6105$	0,0057 < 0,0001

Untuk mengetahui apakah parameter pada model *ARIMA* deret *noise* yang digunakan signifikan atau tidak maka dilakukan uji hipotesis sebagai berikut

1. Hipotesis

H_0 : Estimasi parameter model *ARIMA* pada deret *noise* tidak signifikan dalam model

H_a : Estimasi parameter model *ARIMA* pada deret *noise* signifikan dalam model

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji
$$t_{hitung} = \frac{estimator}{SE(estimator)}$$

4. Kriteria keputusan tolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2}, df}$ atau $p\text{-value} < 0,05$.

5. Perhitungan ada pada tabel 3.15

6. Kesimpulan

Berdasarkan tabel 3.15 memperlihatkan hasil estimasi parameter dan nilai $p\text{-value}$ masing-masing deret *noise*. Nilai $p\text{-value}$ untuk semua parameter tersebut kurang dari taraf signifikansi alpha 0,05 sehingga H_0 ditolak dan disimpulkan bahwa parameter tersebut signifikan artinya dapat dimasukkan ke dalam model. Selanjutnya untuk mengetahui autokorelasi residulnya tidak signifikan berbeda nyata dari nol dapat dilakukan uji hipotesis berikut ini:

1. Hipotesis

H_0 : $\rho_1 = \dots = \rho_k = 0$ (autokorelasi residualnya tidak signifikan)

H_1 : $\exists \rho_i \neq 0$ (autokorelasi residualnya signifikan)

2. Taraf signifikansi $\alpha = 0,05$
3. Statistik uji $Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k}$
4. Kriteria keputusan tolak H_0 jika $Q \geq \chi_{\alpha, df}^2$ atau $p\text{-value} \leq \alpha$
5. Perhitungan dilakukan dengan program *SAS* dan hasilnya seperti yang terlihat pada tabel 3.16

Tabel 3.16 Uji *Ljung-Box* Masing-masing Deret *Noise*

Model <i>ARIMA</i>	Lag	<i>Chi-Square</i>	df	$\chi_{\alpha, df}^2$	P-Value
Deret <i>noise</i> pertama (1,0,0)(0,0,1) ¹²	6	6,82	4	9,49	0,1460
	12	10,07	10	18,31	0,4341
	18	14,67	16	26,30	0,5488
	24	17,71	22	33,92	0,7229
Deret <i>noise</i> kedua (0,0,1)(1,0,0) ¹²	6	8,21	4	9,49	0,0842
	12	9,90	10	18,31	0,4489
	18	13,61	16	26,30	0,6281
	24	20,28	22	33,92	0,5655
Deret <i>noise</i> ketiga (1,0,0)(0,0,1) ¹²	6	6,40	4	9,49	0,1712
	12	9,02	10	18,31	0,5303
	18	12,85	16	26,30	0,6840
	24	15,54	22	33,92	0,8380
Deret <i>noise</i> keempat (0,0,1)(1,0,0) ¹²	6	8,25	4	9,49	0,0828
	12	9,96	10	18,31	0,4438
	18	13,70	16	26,30	0,6213
	24	20,30	22	33,92	0,5643

6. Kesimpulan

Berdasarkan tabel 3.16 memperlihatkan nilai Q yang lebih besar dari nilai tabel χ_{df}^2 dengan derajat bebas banyaknya lag maksimum dikurangi banyaknya parameter atau dapat dilihat dari nilai *p-value* yang lebih dari alpha 0.05. Oleh karena semua nilai *p-value* lebih dari alpha maka dapat disimpulkan H_0 diterima yang artinya autokorelasi residualnya tidak signifikan atau residual pada model

ARIMA untuk deret *noise* memenuhi asumsi *white noise* yaitu korelasi antar lag bersifat independen.

Setelah didapat model *ARIMA* untuk deret *noise* maka model fungsi transfer input tunggal yang terbentuk menjadi sebagai berikut:

$$y_{1t} = \omega_0(x_1)_{t-3} + \frac{(1 - \Theta_1 B^{12})}{(1 - \phi_1 B)} a_t \quad (3.55)$$

$$y_{2t} = \omega_0(x_2)_t + \frac{(1 - \theta_1 B)}{(1 - \Phi_1 B^{12})} a_t \quad (3.56)$$

$$y_{3t} = \omega_0(x_3)_{t-4} + \frac{(1 - \Theta_1 B^{12})}{(1 - \phi_1 B)} a_t \quad (3.57)$$

$$y_{4t} = \omega_0(x_4)_{t-12} + \frac{(1 - \theta_1 B)}{(1 - \Phi_1 B^{12})} a_t \quad (3.58)$$

2. Tahap Kedua : Penaksiran Parameter-parameter Model Fungsi Transfer

Setelah tahap pertama selesai maka selanjutnya adalah menaksirkan parameter-parameter model fungsi transfer. Pada tahap sebelumnya yakni penetapan nilai (r,s,b) telah diidentifikasi model fungsi transfer input tunggal dan telah didapatkan pula model *ARIMA* untuk deret *noisenya* maka model fungsi transfernya telah didapat sehingga langkah berikutnya adalah menentukan parameter model fungsi transfer tersebut. Penentuan parameter model fungsi transfer ini didasarkan pada nilai (r,s,b) dan dikerjakan menggunakan program SAS 9.1.3 Berikut hasil estimasi parameter model fungsi transfer input tunggal yang dihasilkan.

Tabel 3.17 Estimasi Parameter Variabel Input Model Fungsi Transfer

Var	Parameter	t-value	p-value	Lag	Shift
X ₁	$\phi_1 = 0,28935$	2,62	0,0106	1	0
	$\Theta_1 = 0,64501$	5,67	<0,0001	12	0
	$\omega_0 = -5,14654$	-2,04	0,0446	0	3
X ₂	$\theta_1 = -0,34937$	-3,30	0,0014	1	0
	$\Phi_1 = -0,72107$	-6,77	<0,0001	12	0
	$\omega_0 = -34,4439$	-3,62	0,0005	0	0
X ₃	$\phi_1 = 0,34422$	3,19	0,0021	1	0
	$\Theta_1 = 0,68455$	6,30	<0,0001	12	0
	$\omega_0 = -12,651$	-2,24	0,0280	0	4
X ₄	$\theta_1 = -0,32070$	-2,72	0,0083	1	0
	$\Phi_1 = -0,71050$	-6,00	<0,0001	12	0
	$\omega_0 = -13,09831$	-2,11	0,0387	0	12

Estimasi parameter model fungsi transfer input tunggal telah didapat maka perlu dilakukan uji hipotesis untuk mengetahui apakah parameternya signifikan atau tidak. Berikut uji hipotesis untuk memeriksa signifikansi parameter terhadap model.

1. Hipotesis

Ho : Estimasi parameter tidak signifikan dalam model

Ho : Estimasi parameter signifikan dalam model

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $t_{hitung} = \frac{estimator}{SE(estimator)}$

4. Kriteria keputusan tolak Ho jika $|t_{hit}| > t_{\frac{\alpha}{2}, df}$ atau $p-value < 0,05$.

5. Perhitungan tersaji dalam tabel 3.17

6. Kesimpulan

Berdasarkan tabel 3.17 terlihat bahwa nilai *p-value* untuk semua parameter kurang dari alpha 0,05 sehingga dapat disimpulkan untuk menolak H_0 yang artinya parameter signifikan dan dapat dimasukkan dalam model.

Langkah selanjutnya adalah melakukan uji diagnostik terhadap model untuk mengetahui kesesuaian deret *noise* model dan tidak adanya korelasi antara residual dengan variabel inputnya.

3. Tahap Ketiga: Uji Diagnosis Model Fungsi Transfer Input Tunggal

3.1. Pemeriksaan Autokorelasi Residual Model

Untuk mengetahui kelayakan suatu model dapat dilihat dari nilai autokorelasi dari model untuk semua variabel input. Adapun hipotesis yang digunakan adalah

1. Hipotesis

H_0 : Autokorelasi residual dari model *noise* tidak signifikan

H_1 : Autokorelasi residual dari model *noise* signifikan

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $Q = (n - r - s - b) \sum_{k=1}^m r_{a\alpha}^2(k)$

4. Kriteria keputusan untuk menolak H_0 jika $Q \geq \chi_{\alpha,df}^2$ atau *p-value* $\leq \alpha$

5. Perhitungan

Berikut adalah hasil autokorelasi residual yang merupakan output dari program SAS untuk masing-masing model fungsi transfer.

Tabel 3.18 Autocorrelation Check of Residuals pada Masing-masing Model Fungsi Transfer

<i>Autocorrelation Check of Residuals (X1)</i>				
To Lag	Chi-Square	df	$\chi^2_{\alpha,df}$	Pr > ChiSq
6	4,06	4	9,49	0,3976
12	7,50	10	18,31	0,6780
18	14,14	16	26,30	0,5885
24	17,52	22	33,92	0,7341
<i>Autocorrelation Check of Residuals (X2)</i>				
To Lag	Chi-Square	df	$\chi^2_{\alpha,df}$	Pr > ChiSq
6	6,16	4	9,49	0,1873
12	9,41	10	18,31	0,4939
18	12,06	16	26,30	0,7401
24	15,60	22	33,92	0,8353
<i>Autocorrelation Check of Residuals (X3)</i>				
To Lag	Chi-Square	df	$\chi^2_{\alpha,df}$	Pr > ChiSq
6	3,06	4	9,49	0,5472
12	6,81	10	18,31	0,7435
18	10,88	16	26,30	0,8170
24	13,87	22	33,92	0,9062
<i>Autocorrelation Check of Residuals (X4)</i>				
To Lag	Chi-Square	df	$\chi^2_{\alpha,df}$	Pr > ChiSq
6	6,75	4	9,49	0,1498
12	9,30	10	18,31	0,5041
18	12,78	16	26,30	0,6886
24	17,68	22	33,92	0,7248

6. Kesimpulan

Berdasarkan tabel 3.18 terlihat bahwa semua nilai *p-value* $\geq 0,05$ H_0 diterima yang berarti bahwa autokorelasi residual dari model *noise* tidak signifikan atau tidak terdapat korelasi antar *lag* sehingga dapat disimpulkan residual memenuhi asumsi *white noise*.

3.2. Pemeriksaan Korelasi Silang Residual

Pemeriksaan korelasi silang berguna untuk mengetahui apakah korelasi antara deret input dengan nilai residualnya tidak signifikan. Pemeriksaan ini dilakukan untuk masing-masing variabel input. Hipotesis yang digunakan sebagai berikut:

1. Hipotesis

H_0 : Korelasi antara model *noise* dengan deret input tidak signifikan

H_1 : Korelasi antara model *noise* dengan deret input signifikan

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji yang digunakan $Q = (n - n^*) \sum_{k=1}^m r_a^2(k)$

4. Kriteria keputusan untuk menolak H_0 jika $Q \geq \chi_{\alpha, df}^2$ atau $p\text{-value} \leq \alpha$

5. Perhitungan

Berikut adalah pemeriksaan korelasi silang residual dapat dilihat pada tabel 3.19 yang didapat dari hasil output program SAS 9.1.3

Tabel 3.19 Crosscorrelation Check of Residuals pada Masing-masing Model Fungsi Transfer

<i>Crosscorrelation Check of Residuals with Input (X1)</i>				
To Lag	Chi-Square	df	$\chi_{\alpha, df}^2$	Pr > ChiSq
5	2,54	5	11,07	0,7698
11	8,98	11	19,68	0,6241
17	12,46	17	27,59	0,7718
23	16,16	23	35,17	0,8483
<i>Crosscorrelation Check of Residuals with Input (X2)</i>				
To Lag	Chi-Square	df	$\chi_{\alpha, df}^2$	Pr > ChiSq
5	9,03	5	11,07	0,1080
11	14,06	11	19,68	0,2298

17	15,56	17	27,59	0,5554
23	27,11	23	35,17	0,2511
<i>Crosscorrelation Check of Residuals with Input (X3)</i>				
To Lag	Chi-Square	df	$\chi^2_{\alpha,df}$	Pr > ChiSq
5	2,92	5	11,07	0,7130
11	10,08	11	19,68	0,5233
17	16,45	17	27,59	0,4924
23	18,59	23	35,17	0,7250
<i>Crosscorrelation Check of Residuals with Input (X4)</i>				
To Lag	Chi-Square	df	$\chi^2_{\alpha,df}$	Pr > ChiSq
5	6,73	5	11,07	0,2413
11	10,19	11	19,68	0,5130
17	15,07	17	27,59	0,5907
23	18,92	23	35,17	0,7058

6. Kesimpulan yang didapat dari perhitungan yang tertuang pada tabel 3.19 adalah nilai *p-value* untuk semua variabel lebih besar dari $\alpha = 0,05$ atau dengan membandingkan nilai Q yang kurang dari $\chi^2_{\alpha,df}$ sehingga dapat disimpulkan H_0 diterima artinya korelasi antara model *noise* dengan deret input tidak signifikan atau deret input α_{it} dengan residual a_{it} memenuhi asumsi *white noise*.

Setelah autokorelasi dan korelasi silang pada residual memenuhi asumsi maka model dapat digunakan. Berikut model fungsi transfer input tunggal yang telah terbentuk.

Model fungsi transfer input tunggal untuk variabel kelembaban udara:

$$y_{1t} = \omega_0(x_1)_{t-3} + \frac{(1 - \Theta_1 B^{12})}{(1 - \phi_1 B)} a_t \quad (3.59)$$

$$y_{1t} = -5,14654(x_1)_{t-3} + \frac{(1-0,64501B^{12})}{(1-0,28935B)} a_t$$

$$(1-B^{12})Y_t = -5,14654(1-B^{12})(X_1)_{t-3} + \frac{(1-0,64501B^{12})}{(1-0,28935B)} a_t$$

Model fungsi transfer input tunggal untuk variabel tekanan udara:

$$y_{2t} = \omega_0(x_2)_t + \frac{(1-\theta_1 B)}{(1-\Phi_1 B^{12})} a_t$$

$$y_{2t} = -34,44396(x_2)_t + \frac{(1+0,34937B)}{(1+0,72107B^{12})} a_t \quad (3.60)$$

$$(1-B^{12})Y_t = -34,44396(1-B^{12})(X_2)_t + \frac{(1+0,34937B)}{(1+0,72107B^{12})} a_t$$

Model fungsi transfer input tunggal untuk variabel temperatur:

$$y_{3t} = \omega_0(x_3)_{t-4} + \frac{(1-\Theta_1 B^{12})}{(1-\phi_1 B)} a_t$$

$$y_{3t} = -12,651(x_3)_{t-4} + \frac{(1-0,68455B^{12})}{(1-0,34422B)} a_t \quad (3.61)$$

$$(1-B^{12})Y_t = -12,651(1-B^{12})(X_3)_{t-4} + \frac{(1-0,68455B^{12})}{(1-0,34422B)} a_t$$

Model fungsi transfer input tunggal untuk variabel kecepatan angin:

$$y_{4t} = \omega_0(x_4)_{t-12} + \frac{(1-\theta_1 B)}{(1-\Phi_1 B^{12})} a_t$$

$$y_{4t} = -13,098831(x_4)_{t-12} + \frac{(1 + 0,32070B)}{(1 + 0,71050B^{12})} a_t \quad (3.62)$$

$$(1 - B^{12})Y_t = -13,098831(1 - B^{12})(X_4)_{t-12} + \frac{(1 + 0,32070B)}{(1 + 0,71050B^{12})} a_t$$

4. Tahap Keempat: Model Fungsi Transfer Multivariat pada Curah Hujan

Pemodelan fungsi transfer multivariat ini dilakukan setelah model fungsi transfer input tunggal telah terbentuk. Kunci dari model fungsi transfer multivariat adalah dengan cara memodelkan secara serentak seluruh variabel yang telah diidentifikasi sebelumnya. Identifikasi fungsi transfer input tunggal menghasilkan nilai-nilai bobot respon impuls dan model deret *noise* yang dijadikan dasar dalam pemodelan serentak yang menghasilkan model fungsi transfer multivariat untuk deret curah hujan di kota Yogyakarta.

Tahap pertama adalah identifikasi model fungsi transfer multivariat. Pada tahap ini model fungsi transfer multivariat ditentukan melalui korelasi silang antara variabel output curah hujan dengan masing-masing variabel inputnya yang menghasilkan nilai-nilai bobot respon impuls. Nilai (r,s,b) untuk kelembaban udara $(0,0,3)$, (r,s,b) untuk tekanan udara $(0,0,0)$, (r,s,b) untuk temperatur $(0,0,4)$ dan (r,s,b) untuk kecepatan angin $(0,0,12)$.

Setelah (r,s,b) ditetapkan maka fungsi transfer multivariat dapat ditulis sebagai berikut:

$$y_t = \sum_{j=1}^k \frac{\omega_j(B)}{\delta_j(B)} B^{bj} x_{jt} + noise \quad (3.63)$$

$$y_t = \sum_{j=1}^k v(B)x_t + noise \quad (3.64)$$

$$\sum_{j=1}^k v(B)x_t = \omega_0(x_1)_{t-3} + \omega_0(x_2)_{t-0} + \omega_0(x_3)_{t-4} + \omega_0(x_4)_{t-12} \quad (3.65)$$

$$y_t = \omega_0(x_1)_{t-3} + \omega_0(x_2)_t + \omega_0(x_3)_{t-4} + \omega_0(x_4)_{t-12} + noise \quad (3.66)$$

Untuk menduga model $ARIMA(p_n, q_n)$ dari *noise* (n_t) dapat dilihat dari plot *ACF* dan *PACF* dari deret *noise* gabungannya yang dapat dilihat pada lampiran 5. Model yang sesuai untuk *noise* adalah $ARIMA(0,0,1)(1,0,0)^{12}$ dan dapat ditulis sebagai berikut:

$$n_t = \frac{(1 - \theta_1 B)}{(1 - \Phi_1 B^{12})} a_t \quad (3.67)$$

Setelah diperoleh model *noise* maka dapat disusun model fungsi transfer multivariat sebagai berikut:

$$y_t = \omega_0(x_1)_{t-3} + \omega_0(x_2)_t + \omega_0(x_3)_{t-4} + \omega_0(x_4)_{t-12} + \frac{(1 - \theta_1 B)}{(1 - \Phi_1 B^{12})} a_t \quad (3.68)$$

$$(1 - B^{12})Y_t = \omega_0(1 - B^{12})(X_1)_{t-3} + \omega_0(1 - B^{12})(X_2)_t + \omega_0(1 - B^{12})(X_3)_{t-4} \\ + \omega_0(1 - B^{12})(X_4)_{t-12} + \frac{(1 - \theta_1 B)}{(1 - \Phi_1 B^{12})} a_t$$

Tahap selanjutnya adalah estimasi parameter model fungsi transfer multivariat. Cara untuk mencari parameter model fungsi transfer multivariat adalah dengan memodelkan secara serentak nilai r, s, b serta melakukan korelasi silang secara serentak. Pemodelan secara serentak ini dilakukan dengan program SAS 9.1.3 dan menghasilkan estimasi parameter sebagai berikut:

Tabel 3.20 Estimasi Parameter Fungsi Transfer Multivariat

<i>Conditional Least Squares Estimation</i>						
Standard			Approx			
Parameter	Estimate	t Value	Pr > t	Lag	Variabel	Shift
θ_1	-0,36175	-3,01	0,0037	1	y	0
Φ_1	-0,86989	-8,16	< 0,0001	12	y	0
ω_0	-2,33515	-1,19	0,2375	0	x1	3
ω_0	-41,9214	-4,57	< 0,0001	0	x2	0
ω_0	-10,3447	-2,32	0,0235	0	x3	4
ω_0	-13,3880	-2,48	0,0156	0	x4	12

Estimasi parameter model fungsi transfer multivariate yang telah didapat perlu dilakukan uji hipotesis untuk mengetahui apakah parameternya signifikan atau tidak. Berikut uji hipotesis untuk memeriksa signifikansi parameter terhadap model.

1. Hipotesis

H_0 : Estimasi parameter tidak signifikan dalam model

H_a : Estimasi parameter signifikan dalam model

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $t_{hitung} = \frac{estimator}{SE(estimator)}$

4. Kriteria keputusan tolak H_0 jika $|t_{hit}| > t_{\frac{\alpha}{2}, df}$ atau $p\text{-value} < 0,05$.
5. Perhitungan ada pada tabel 3.20
6. Kesimpulan

Berdasarkan tabel 3.20 estimasi hasil pemodelan serentak menunjukkan adanya variabel yang tidak signifikan dengan taraf signifikansi $\alpha = 0.05$ yaitu variabel input kelembaban hal itu karena kelembaban udara berkorelasi terhadap variabel lain, sehingga perlu dikeluarkan dari model. Setelah variabel pertama dikeluarkan dari model maka didapat estimasi parameter sebagai berikut:

Tabel 3.21 Estimasi Parameter Akhir Fungsi Transfer Multivariat

<i>Conditional Least Squares Estimation</i>						
Standard			Approx			
Parameter	Estimate	t Value	Pr > t	Lag	Variabel	Shift
θ_1	-0,34972	-2,95	0,0044	1	y	0
Φ_1	-0,88011	-8,50	< 0,0001	12	y	0
ω_0	-43,22914	-4,74	< 0,0001	0	x2	0
ω_0	-10,39131	-2,32	0,0233	0	x3	4
ω_0	-13,63130	-2,54	0,0135	0	x4	12

Uji hipotesis untuk memeriksa signifikansi parameter terhadap model adalah sebagai berikut:

1. Hipotesis

H_0 : Estimasi parameter tidak signifikan dalam model

H_a : Estimasi parameter signifikan dalam model

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $t_{hitung} = \frac{estimator}{SE(estimator)}$

4. Kriteria keputusan tolak H_0 jika $|t_{hit}| > t_{\frac{\alpha}{2}, df}$ atau $p-value < 0,05$.

5. Perhitungan tersaji pada tabel 3.21

6. Kesimpulan

Berdasarkan tabel 3.21 $p-value$ parameter setelah variabel pertama dikeluarkan dalam model maka parameter tekanan udara, temperatur, kecepatan angin dan deret *noise* dari model fungsi transfer multivariat menolak H_0 sehingga parameter menjadi signifikan. Hal itu terlihat dari nilai $p-value$ masing-masing parameter kurang dari 0,05 atau nilai $|t_{hit}|$ yang lebih besar dari $t_{(\alpha/2, df)}$ yakni diantara 2,00 sampai 1,98 dengan $df = n - np$. Model fungsi transfer multivariat akhir yang didapatkan untuk output curah hujan adalah sebagai berikut:

$$(1 - B^{12})Y_t = -43,22914(1 - B^{12})(X_2)_t - 10,39131(1 - B^{12})(X_3)_{t-4} \quad (3.69)$$

$$-13,6313(1 - B^{12})(X_4)_{t-12} + \frac{(1 + 0,34972B)}{(1 + 0,88011B^{12})}a_t$$

Setelah dilakukan estimasi parameter dan nilai parameter telah signifikan maka tahap selanjutnya adalah pemeriksaan diagnosis model multivariat. Untuk mengetahui kelayakan suatu model perlu dilakukan pengujian terhadap kesesuaian deret *noise* dan ada tidaknya autokorelasi antara residual dengan variabel inputnya. Berikut pemeriksaan autokorelasi untuk residual model. Adapun hipotesis yang digunakan adalah

1. Hipotesis

H_0 : Autokorelasi antara residual dengan variabel inputnya tidak signifikan

H_1 : Autokorelasi antara residual dengan variabel inputnya signifikan

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $Q = (n - r - s - b) \sum_{k=1}^m r_{aa}^2(k)$

4. Kriteria keputusan untuk menolak H_0 jika $Q \geq \chi_{\alpha, df}^2$ atau $p\text{-value} \leq \alpha$

5. Perhitungan

Tabel 3.22 merupakan hasil perhitungan autokorelasi residual yang merupakan output dari program SAS.

Tabel 3.22 Autocorrelation Check of Residuals pada

Model Fungsi Transfer Multivariat

<i>Autocorrelation Check of Residuals</i>				
To Lag	Chi-Square	df	$\chi_{\alpha, df}^2$	Pr > ChiSq
6	4,66	4	9,49	0,3238
12	13,24	10	18,31	0,2108
18	17,49	16	26,30	0,3546
24	22,42	22	33,92	0,4348

6. Kesimpulan

Berdasarkan tabel 3.22 terlihat bahwa $p\text{-value} > 0,05$ atau $Q_{\text{hit}} < \chi_{\alpha, df}^2$ sehingga keputusannya H_0 diterima hal ini berarti autokorelasi antara residual dengan variabel inputnya tidak signifikan. Residual fungsi transfer multivariat pada semua lag telah memenuhi asumsi *white noise*.

Selanjutnya adalah pemeriksaan korelasi silang untuk deret input dengan nilai residual. Hal ini berguna untuk mengetahui apakah korelasi antara deret input dengan deret *noise* signifikan atau tidak. Pemeriksaan ini dilakukan untuk masing-masing variabel input. Adapun hipotesis yang digunakan adalah:

1. Hipotesis

H_0 : Korelasi antara deret *noise* dengan deret input tidak signifikan

H_1 : Korelasi antara deret *noise* dengan deret input signifikan

2. Taraf signifikansi $\alpha = 0,05$

3. Statistik uji $Q = (n - n^*) \sum_{k=1}^m r_a^2(k)$

4. Kriteria keputusan untuk menolak H_0 jika $Q \geq \chi_{\alpha, df}^2$ atau $p\text{-value} \leq \alpha$

5. Perhitungan

Berikut adalah perhitungan korelasi silang residual pada model fungsi transfer multivariate hasil output program SAS 9.1.3

Tabel 3.23 Crosscorrelation Check of Residuals pada Model Fungsi Transfer Multivariat

<i>Crosscorrelation Check of Residuals with Input x2</i>				
To Lag	Chi-Square	df	$\chi_{\alpha, df}^2$	Pr > ChiSq
5	6,82	5	11,07	0,2346
11	16,75	11	19,68	0,1154
17	17,75	17	27,59	0,4048
23	26,84	23	35,17	0,2628
<i>Crosscorrelation Check of Residuals with Input x3</i>				
To Lag	Chi-Square	df	$\chi_{\alpha, df}^2$	Pr > ChiSq
5	9,04	5	11,07	0,1076
11	14,09	11	19,68	0,2279
17	22,16	17	27,59	0,1786
23	24,68	23	35,17	0,3670

<i>Crosscorrelation Check of Residuals with Input x4</i>				
To Lag	Chi-Square	df	$\chi^2_{\alpha,df}$	Pr > ChiSq
5	4,08	5	11,07	0,5385
11	6,24	11	19,68	0,8571
17	10,83	17	27,59	0,8651
23	17,03	23	35,17	0,8079

6. Kesimpulan

Berdasarkan tabel 3.23 *p-value* masing-masing variabel lebih dari taraf signifikansi $\alpha = 0.05$ sehingga dapat disimpulkan H_0 diterima, korelasi antara model *noise* dengan deret input tidak signifikan. Oleh karena model telah memenuhi *white noise* maka model fungsi transfer multivariat dapat digunakan.

5. Tahap Kelima: Penggunaan Model Fungsi Transfer untuk Peramalan


Hasil estimasi model fungsi transfer multivariat menghasilkan parameter yang dapat digunakan untuk meramalkan curah hujan. Berikut merupakan hasil peramalan curah hujan dengan menggunakan model fungsi transfer multivariat yang berasal dari output program SAS 9.1.3

Tabel 3.24 Hasil Ramalan Curah Hujan dengan Model Transfer Multivariat

tahun bulan	2010 (dalam satuan mm)	2011 (dalam satuan mm)
Januari	46,32	65,09
Februari	182,26	428,93
Maret	218,88	384,54
April	80,07	458,59
Mei	71,73	96,69
Juni	6,41	97,01
Juli	0,37	11,69
Agustus	4,99	17,21

September	5,74	50,48
Oktober	13,23	107,13
November	78,08	154,37
Desember	142,51	235,24

Untuk lebih jelasnya berikut disajikan hasil ramalan curah hujan tahun 2010 dan 2011 dalam bentuk plot *time series* .



Gambar 3.23 Plot *Time Series*

Hasil Ramalan Tahun 2010-2011

Pada tahun 2011 nampak terjadi peningkatan curah hujan khususnya pada bulan Februari, Maret dan April. Pada bulan-bulan selanjutnya banyaknya curah hujan juga mengalami peningkatan akan tetapi ada juga yang nilainya mendekati yakni pada bulan Januari, Mei, Juli dan Agustus. Berdasarkan model fungsi transfer yang terbentuk menunjukkan bahwa banyaknya curah hujan selain dipengaruhi oleh ketiga variabel input juga dipengaruhi oleh banyak curah hujan itu sendiri pada tahun-tahun sebelumnya. Ramalan curah hujan pada tahun 2010 mendekati banyak curah hujan pada tahun 2008 sedangkan ramalan tahun 2011 hasilnya hampir sama dengan curah hujan tahun 2009. Hal itu menunjukkan setelah terjadi curah hujan yang tinggi pada tahun sebelumnya maka curah hujan akan menjadi turun di tahun berikutnya. Curah hujan maksimum pada tahun 2010 adalah 218,88mm pada bulan Maret, sedangkan pada tahun 2011 adalah 458,59mm pada bulan April. Curah hujan minimum untuk kedua tahun terjadi pada bulan Juli yaitu 0,37mm untuk tahun 2010 dan 11,69mm pada tahun 2011. Rata-rata curah hujan pada tahun 2010 adalah 70,88mm dan pada tahun 2011 adalah 175,58mm.

BAB IV

KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil pembahasan mengenai model fungsi transfer multivariat beserta aplikasinya dalam meramalkan curah hujan di Kota Yogyakarta maka dapat disimpulkan sebagai berikut:

1. Prosedur untuk menentukan model fungsi transfer multivariat yakni melalui beberapa tahapan antara lain:
 - i. Pengidentifikasian variabel input dan output sehingga tercapailah kestasioneran baik dalam rata-rata maupun varians. Setelah variabel yang akan digunakan telah stasioner maka dilakukan penentuan order model *ARIMA* untuk setiap masing-masing variabel input.
 - ii. Setelah model *ARIMA* yang sesuai didapat kemudian dilakukan pemutihan variabel input dan output. Apapun model yang didapat pada variabel input ditransformasikan ke variabel output sehingga output dapat diputihkan.

- iii. Perhitungan korelasi silang dilakukan antara masing-masing variabel input dengan output yang telah diputihkan. Nilai pada korelasi silang digunakan untuk menghitung bobot respon impuls dengan menggunakan rumus

$$v_k = r_{\alpha\beta}(k) \frac{S_\beta}{S_\alpha}$$

yang berguna untuk mencari deret *noise*nya.

- iv. Penentuan nilai r, s, b dengan menganalisis plot pada korelasi silang sehingga telah dapat ditentukan model fungsi transfer tahap awal dengan rumus umumnya $y_t = v(B)x_t + noise$
- v. Penentuan deret *noise* dengan menggunakan rumus

$$n_t = y_t - v_0 x_t - v_1 x_{t-1} - v_2 x_{t-2} - \dots - v_{19} x_{t-19}$$

lalu dicari model *ARIMA* untuk deret tersebut. Setelah didapatkan model *ARIMA* dari deret *noise* dan nilai r, s, b juga telah diketahui maka model fungsi transfer input tunggal telah terbentuk dengan rumus umum sebagai berikut:

$$y_t = \frac{\omega(B)}{\delta(B)} x_{t-b} + \frac{\theta(B)}{\phi(B)} a_t$$

- vi. Penaksiran parameter untuk masing-masing model fungsi transfer input tunggal lalu dilakukan diagnosis untuk mengetahui apakah parameter telah signifikan dan residual sudah memenuhi asumsi *white noise*.
- vii. Hasil dari identifikasi model fungsi transfer input tunggal digunakan untuk mengestimasi parameter model fungsi transfer multivariat dengan cara

melakukan korelasi silang secara serentak dan mengestimasi secara bersama nilai-nilai r, s, b yang telah diidentifikasi sebelumnya pada model fungsi transfer input tunggal.

- viii. Diagnosis pada model fungsi transfer multivariat dilakukan untuk mengetahui kelayakan suatu model. Apabila ada variabel input yang saling berkorelasi dengan variabel input lainnya maka akan terjadi nilai parameter yang tidak signifikan sehingga salah satu dari variabel tersebut harus dikeluarkan dari model. Berikut merupakan rumus umum dari model fungsi transfer multivariat

$$y_t = \sum_{j=1}^k v_j(B)x_{jt} + n_t$$

2. Model peramalan banyaknya curah hujan di Kota Yogyakarta tahun 2010 sampai 2011 dengan menggunakan model fungsi transfer multivariat yang melibatkan variabel input tekanan udara, temperatur dan kecepatan angin adalah sebagai berikut:

$$(1 - B^{12})Y_t = -43,22914(1 - B^{12})(X_2)_t - 10,39131(1 - B^{12})(X_3)_{t-4} \quad (3.58)$$

$$-13,6313(1 - B^{12})(X_4)_{t-12} + \frac{(1 + 0,34972B)}{(1 + 0,88011B^{12})}a_t$$

$$Y_t + 0,88Y_{t-12} - Y_{t-12} - 0,88Y_{t-24} = -43,229(X_2)_t - 38,04(X_2)_{t-12} + 43,229(X_2)_{t-12}$$

$$+ 38,04(X_2)_{t-24} - 10,39(X_3)_{t-4} - 9,14(X_3)_{t-16} + 10,39(X_3)_{t-16} + 9,14(X_3)_{t-28}$$

$$-13,63(X_4)_{t-12} - 11,99(X_4)_{t-24} + 13,63(X_4)_{t-24} + 11,99(X_4)_{t-36} + a_{t-1} + 0,349a_{t-1}$$

$$\begin{aligned}
Y_t = & -0,88Y_{t-12} + Y_{t-12} + 0,88Y_{t-24} - 43,229(X_2)_t - 38,04(X_2)_{t-12} + 43,229(X_2)_{t-12} \\
& + 38,04(X_2)_{t-24} - 10,39(X_3)_{t-4} - 9,14(X_3)_{t-16} + 10,39(X_3)_{t-16} + 9,14(X_3)_{t-28} \\
& - 13,63(X_4)_{t-12} - 11,99(X_4)_{t-24} + 13,63(X_4)_{t-24} + 11,99(X_4)_{t-36} + a_{t-1} + 0,349a_{t-1}
\end{aligned}$$

Berdasarkan model fungsi transfer multivariat di atas dapat diketahui bahwa ramalan curah hujan pada waktu ke-t dipengaruhi oleh banyaknya curah hujan pada duabelas bulan sebelumnya dan duapuluh empat bulan sebelumnya (Y_{t-12} , Y_{t-24}), kelembaban udara pada waktu duabelas bulan sebelumnya dan duapuluh empat bulan sebelumnya ($(X_2)_t$, $(X_2)_{t-12}$, $(X_2)_{t-24}$, $(X_3)_{t-4}$), temperatur pada enambelas bulan sebelumnya dan duapuluh delapan bulan sebelumnya ($(X_3)_{t-16}$, $(X_3)_{t-28}$), serta dipengaruhi oleh kecepatan angin pada duabelas, duapuluh empat dan tigapuluh enam bulan sebelumnya ($(X_4)_{t-12}$, $(X_4)_{t-24}$, $(X_4)_{t-36}$). Terjadinya pengaruh pada bulan-bulan tertentu tersebut dikarenakan curah hujan merupakan fenomena musiman sehingga banyaknya curah hujan pada bulan t hampir sama dengan banyak curah hujan pada duabelas bulan sebelumnya sampai duapuluh empat bulan sebelumnya.

3. Hasil ramalan banyaknya curah hujan pada bulan Januari 2010 sampai Desember 2011 adalah sebagai berikut:

Setelah model fungsi transfer terbentuk maka model tersebut dapat digunakan untuk meramal. Hasil dari ramalan berdasarkan model fungsi transfer multivariat dengan melibatkan tiga variabel input dengan variabel output dari periode Januari 2002

sampai Desember 2009 adalah ramalan dari tahun 2010 sampai dengan 2011 dapat dilihat dari tabel 3.24 pada pembahasan hal 103. Pada tabel tersebut terlihat adanya peningkatan banyaknya curah hujan pada tahun 2011. Peningkatan tersebut terjadi hampir pada setiap bulannya. Akan tetapi peningkatan yang signifikan terjadi pada bulan Februari, April dan Oktober. Curah hujan maksimum pada tahun 2010 adalah 218,88mm terjadi pada bulan Maret, sedangkan pada tahun 2011 adalah 458,59mm terjadi pada bulan April. Curah hujan minimum untuk kedua tahun terjadi pada bulan Juli yaitu 0,37mm untuk tahun 2010 dan 11,69mm pada tahun 2011. Rata-rata curah hujan pada tahun 2010 adalah 70,88mm dan pada tahun 2011 adalah 175,58mm.

B. Saran

Pada model *ARIMA* apabila data tidak stasioner dalam rata-rata maka perlu dilakukan *differencing*, sedangkan untuk model fungsi transfer hal itu menjadi kendala bila terjadi perbedaan *differencing* antara variabel satu dengan variabel lainnya. Selain itu pemilihan model *ARIMA* yang terbaik belum tentu dapat memenuhi asumsi *white noise* pada autokorelasi deret input yang telah diputihkan.

Di dalam skripsi ini masih ada beberapa kelemahan antara lain deret input kecepatan angin yang telah stasioner tanpa pembeda akan tetapi tetap dilakukan pembeda duabelas dikarenakan variabel output dan input yang lain juga dipembeda duabelas. Selain itu autokorelasi deret input yang telah diputihkan belum memenuhi asumsi *white noise*. Hal ini tentu saja berpengaruh terhadap hasil ramalan. Oleh karenanya, perlu adanya pendekatan model yang lebih fleksibel agar hasil ramalan dengan pemodelan fungsi transfer menjadi lebih akurat. Misalnya dengan pendekatan fuzzy atau *neural network*.

Daftar Pustaka

- Box, G.E.P., & G.M.Jenkins. 1976. *Time Series Analysis, Forecasting and Control*. Edisi Revisi. San Francisco: Holden day
- BPS Kota Yogyakarta. 2009. *Kota Yogyakarta dalam Angka*. Yogyakarta: BPS Yogyakarta
- Chatfield, C. 2004. *The Analysis of Times Series An Introduction*. Florida: CRC Press Company.
- Fathurahman. 2009. *Pemodelan Fungsi Transfer Multi Input*. Jurnal Informatika
- Hanke, J.E dan Wicheren DW. 2005. *Business Forcadting*. 8th edition. Fngewood: Cliffs Prentice Hall
- Haryasyifha ,nanda. 2010. *Analisis Deret Berkala*. <http://www.blogspot.com/analisis-deret-berkala.html>
- Kustituantto, Bambang. 1984. *Statistik Analisa Runtut Waktu dan Regresi Korelasi*. Yogyakarta : BPFE
- Makridakis Spyros, Wheel Wright Steven C, dan Victor E, McGEE. 1993. *Metode Dan Aplikasi Peramalan*. Edisi Ke-2. Jakarta: Erlangga
- Munchan _xp. 2010. *Analisis Deret Berkala Multivariat Fungsi Transfer*. http://www.blogspot.com/munchan_xp/analisis-deret-berkala.html
- Pangestu, S. 1956. *Forcesting : Konsep dan Aplikasinya*. Yogyakarta : BPFE

Santoso, S. 2009. *Bussiness Forecasting Metode Peramalan Bisnis masa Kini dengan Minitab dan SPSS*. Jakarta: Elex Media Komputindo

Soewarno. 2000. *Hidrologi Operasional*. Jilid kesatu. Bandung: Citra Aditya Bakti

Sosrodarsono, Suyono. 1985. *Hidrologi*. Jakarta: PT Pradnya Paramita

Suhartono. 2005. *Modul Analisis Times Series*. Modul Perkuliahan. Surabaya: ITS Surabaya.

Wei, W.S William. 1990. *Univariate and Multivariate Methods*. California. Addison Wesley Publishing Company

Wilson, E.M. 1993. *Hidrologi Teknik*. Edisi ke-4. Jakarta : Erlangga

Lampiran 1

Tabel Data Output (Y_t) dan Data Input (X_{jt}) Periode Januari 2002- Desember 2009

t	Periode	Output curah hujan (Y_t)	Input Kelembaban (X_{1t})	Input Tekanan udara (X_{2t})	Input Temperatur (X_{3t})	Input Kec_angin (X_{4t})
1	Jan-02	162	85	1009.8	26.5	2
2	Feb-02	207	87	1010.3	26.2	2
3	Mar-02	296	83	1009.6	27.1	2
4	Apr-02	52	83	1009.4	27.1	2
5	May-02	90	80	1010.4	27.2	2
6	Jun-02	84	78	1011.2	26.2	2
7	Jul-02	6	75	1010.8	25.9	2
8	Aug-02	2	73	1010.5	31.1	3
9	Sep-02	30	72	1012.8	26.2	3
10	Oct-02	1	73	1012.1	33.2	3
11	Nov-02	21	80	1010.9	27.8	3
12	Dec-02	70	84	1010.9	27.8	3
13	Jan-03	130	84	1010.8	26.6	3
14	Feb-03	244	84	1009.2	26.4	2
15	Mar-03	157	83	1010	27	2
16	Apr-03	50	79	1010	26.6	2
17	May-03	46	79	1010.4	24.1	2
18	Jun-03	4	82	1011.2	26.4	2
19	Jul-03	0	66	1013.3	23.2	2
20	Aug-03	0	65	1013.6	25.3	2

21	Sep-03	2	72	1013.7	25.8	3
22	Oct-03	36	78	1012.6	25.8	2
23	Nov-03	101	84	1011.2	31.1	4
24	Dec-03	210	85	1010.7	27.8	4
25	Jan-04	161	85	1010.7	28.8	8
26	Feb-04	157	86	1010.2	26.4	10
27	Mar-04	147	86	1009.9	26.6	8
28	Apr-04	15	79	1011	28.1	4
29	May-04	59	82	1010.8	27.1	4
30	Jun-04	1	79	1011.9	25.9	4
31	Jul-04	20	78	1010.7	26.2	5
32	Aug-04	0	64	1012.6	25.4	6
33	Sep-04	7	73	1011.8	26.8	4
34	Oct-04	14	72	1011.9	27.5	5
35	Nov-04	101	81	1009.9	27.6	5
36	Dec-04	271	85	1010.2	26.7	8
37	Jan-05	180.4	85	1009.8	26.5	2
38	Feb-05	174.8	87	1010.3	26.2	2
39	Mar-05	166.6	83	1009.6	27.1	2

Sumber: BPS Kota Yogyakarta

t	Periode	Output curah hujan (Y_t)	Input Kelembaban (X_{1t})	Input Tekanan udara (X_{2t})	Input Temperatur (X_{3t})	Input Kec_angin (X_{4t})
40	Apr-05	118.6	83	1009.4	27.1	2
41	May-05	22.2	80	1010.4	27.2	2
42	Jun-05	34.8	78	1011.2	26.2	2
43	Jul-05	77.2	75	1012.5	25.9	2
44	Aug-05	0.6	73	1013.1	31.1	3
45	Sep-05	32	72	1013.8	26.2	3
46	Oct-05	97.8	72	1012.1	33.2	3
47	Nov-05	0	80	1010.9	27.8	3
48	Dec-05	141.6	72	1010.9	27.8	3
49	Jan-06	292.8	87	1009.2	26.4	4
50	Feb-06	242.6	86	1009.6	26.8	3
51	Mar-06	387.6	90	1008.9	26.6	4
52	Apr-06	231.6	87	1009.6	26.5	4
53	May-06	191.4	85	1010.9	26.6	2
54	Jun-06	0	81	1011.6	25.6	3
55	Jul-06	0	79	1012.9	24.9	3
56	Aug-06	0	74	1013.1	25.1	4
57	Sep-06	3	73	1013.8	25.7	5
58	Oct-06	0.4	72	1013.7	27.5	5

59	Nov-06	30.8	72	1011.2	29	5
60	Dec-06	278	83	1009.7	27.5	4
61	Jan-07	57	81	1010.8	27	5
62	Feb-07	377	82	1010.2	27.3	4
63	Mar-07	294	84	1008.9	26.6	5
64	Apr-07	289	86	1010	27	3
65	May-07	55	80	1010.5	27.5	4
66	Jun-07	22	79	1009.2	26.4	4
67	Jul-07	2	78	1011.5	25.7	4
68	Aug-07	3	75	1012.3	25.5	5
69	Sep-07	29	73	1012.4	26	6
70	Oct-07	64	75	1011.2	27.5	6
71	Nov-07	203	82	1010.2	26.8	5
72	Dec-07	524	80	1008.1	26.4	5
73	Jan-08	145.8	83	1009	26.3	6
74	Feb-08	210.8	84	1008	25.8	5
75	Mar-08	220	85	1009	25.7	4
76	Apr-08	70.8	79	1009	26.8	4
77	May-08	41.6	75	1011	26.3	3
78	Jun-08	3.6	73	1011	25.6	3.3
79	Jul-08	13.2	60	1012	24.4	3
80	Aug-08	20	69	1012	25.7	4
81	Sep-08	30	66	1012	27	5.4
82	Oct-08	34.7	71	1011	27.5	4.6

t	Periode	Output curah hujan (Y_t)	Input Kelembaban (X_{1t})	Input Tekanan udara (X_{2t})	Input Temperatur (X_{3t})	Input Kec_angin (X_{4t})
83	Nov-08	101.2	81	1009	26.3	4
84	Dec-08	143.9	81	1009	25.9	5
85	Jan-09	44.2	80	1009	26.2	5
86	Feb-09	473.9	83	1008	25.7	5
87	Mar-09	385.9	78	1010	26.7	4
88	Apr-09	519.3	77	1009	27.3	4
89	May-09	145.1	78	1009	26.8	4
90	Jun-09	100.9	73	1011	26.6	4
91	Jul-09	0	60	1012	25.2	4
92	Aug-09	15	68	1012	25.4	5
93	Sep-09	47.8	66	1012	26.8	6
94	Oct-09	88.3	77	1012.1	27.8	5
95	Nov-09	171.9	75	1009.5	27.9	4
96	Dec-09	199.9	80	1010.4	27.5	4

Lampiran 2. Tabel Deret Input (α_{jt}) dan Deret Output (β_t) yang Diputihkan

t	α_{1t}	β_{1t}	t	α_{2t}	β_{2t}
1	0	0	1	0	0
2	0	0	2	0	0
3	0	0	3	0	0
4	0	0	4	0	0
5	0	0	5	0	0
6	0	0	6	0	0
7	0	0	7	0	0
8	0	0	8	0	0
9	0	0	9	0	0
10	0	0	10	0	0
11	0	0	11	0	0
12	0	0	12	0	0
13	0	0	13	0	0
14	0	0	14	-1.888	62.216
15	1.02726	-140.468	15	0.37685	-138.829
16	-3.24202	24.54138	16	0.46244	42.09206
17	0.0328	-8.36386	17	-0.25482	-22.5831
18	5.26884	-68.1339	18	-0.12011	-55.973
19	-9.78014	25.77304	19	2.44338	30.65602
20	-6.68684	19.762	20	2.28174	17.17833
21	4.33954	-25.9676	21	-0.46726	-18.3267
22	7.02128	42.73492	22	-0.42945	48.42537
23	2.709	78.03748	23	-0.29643	75.24626
24	-1.2961	110.5009	24	-0.57613	112.4288
25	-0.26884	-25.3608	25	-0.21397	-26.3244
26	1.48914	-130.377	26	-0.24578	-83.5106

27	3.156029	-121.866	27	-0.18281	-89.799
28	-4.19949	11.66391	28	1.17723	0.246191
29	2.271558	17.03161	29	-0.13953	13.19948
30	0.970201	-58.8708	30	0.31903	-36.4025
31	3.209213	40.69967	31	-1.38082	42.17471
32	-9.36219	13.39045	32	1.1304	5.888785
33	2.134209	-23.4381	33	-1.57909	-9.35079
34	0.317403	15.1935	34	-0.08274	6.638498
35	0.736103	74.69297	35	-0.84834	54.44286
36	1.12337	166.069	36	-0.15835	136.5469
37	0.515879	-19.1886	37	-0.54332	-15.7133
38	2.34103	-120.031	38	0.45916	-50.9801
39	-0.41607	-99.6431	39	-0.20577	-51.1485

t	α_{1t}	β_{1t}	t	α_{2t}	β_{2t}
40	0.740132	104.5458	40	-0.64171	91.63848
41	-0.22919	-53.164	41	0.10824	-66.761
42	-0.62054	-35.8893	42	-0.08438	3.702193
43	0.653544	94.42241	43	1.31937	70.76762
44	1.596236	-10.6503	44	0.85803	-20.1834
45	-0.64388	-10.714	45	0.64161	7.153538
46	-1.72991	90.87576	46	-0.64478	74.63144
47	-0.08445	-61.6897	47	0.01389	-98.5958
48	-11.7302	25.05707	48	0.07508	-24.4152
49	6.07383	154.0496	49	-1.41999	150.9588
50	3.876371	-36.6199	50	-0.43295	22.14339
51	6.378192	85.36246	51	-0.62612	160.4333
52	3.111779	132.9551	52	0.1034	89.49773
53	1.992184	36.30922	53	0.65733	51.07518
54	0.139543	-139.358	54	0.22809	-121.259
55	2.550643	-25.9336	55	1.07326	-62.1978
56	0.646695	18.53458	56	0.34378	-3.78615
57	-0.84868	-18.9881	57	0.31578	-19.5092
58	-2.06871	-7.92334	58	1.13492	-37.5564
59	-8.32871	7.721822	59	-0.21985	3.142531
60	2.502121	175.6214	60	-1.49561	127.907
61	-1.34919	-140.073	61	0.89729	-177.687
62	-1.73923	127.843	62	-0.08466	204.6884
63	2.292577	8.147456	63	-0.78627	-5.80154
64	4.362121	167.3414	64	0.28768	137.4186
65	-1.4318	-94.8738	65	-0.18513	-111.093
66	-0.33068	-82.7815	66	-2.22504	-17.0815
67	3.076656	7.428222	67	0.06834	-26.6572
68	2.345894	13.61621	68	0.23036	5.406025
69	-0.76981	7.62051	69	-0.56136	14.69581
70	0.884385	48.99353	70	-1.02227	31.6567
71	1.725063	156.1631	71	-0.00109	150.5155

72	-4.08672	343.6229	72	-1.71474	263.1991
73	-0.967	-144.366	73	-0.30898	-135.229
74	0.675331	-136.155	74	-1.25624	-112.963
75	2.042838	-46.1863	75	0.75768	-62.5744
76	-3.83526	-6.40349	76	-0.29499	-98.5421
77	-4.73465	-23.8016	77	0.94107	-1.89553
78	-3.23817	-34.3577	78	0.46397	14.13305
79	-12.4168	26.02594	79	0.02435	20.30139
80	2.276132	31.01904	80	-0.55409	29.39159
81	-1.59616	0.643382	81	-0.85901	9.33201
82	0.119784	10.26721	82	-0.78081	-9.66013
	α_{1t}	β_{1t}	t	α_{2t}	β_{2t}
83	3.354908	46.14374	83	-1.09885	4.62194
84	-1.41141	-36.9661	84	0.21654	-173.09
85	-3.87636	-107.745	85	-0.28354	-51.7283
86	0.130103	262.7564	86	-0.8535	286.872
87	-4.14416	82.04526	87	1.47256	87.75203
88	-3.39374	333.4232	88	-0.51655	314.3799
89	1.021277	-75.6533	89	-1.5434	-72.8527
90	-3.18538	-73.6822	90	0.86172	-8.85903
91	-11.9398	-41.0358	91	0.28023	-85.2074
92	1.049748	1.758312	92	-0.23449	-21.9142
93	-1.17921	23.0055	93	-0.49803	8.479797
94	6.36053	59.51338	94	0.62158	34.45848
95	-4.52797	93.91742	95	-0.5475	50.65282
96	-2.2378	-9.0868	96	1.22398	-89.4376

t	α_{3t}	β_{3t}	t	α_{4t}	β_{4t}
1	0	0.00	1	0.00	0
2	0	0.00	2	0.00	0
3	0	0.00	3	0.00	0
4	0	0.00	4	0.00	0
5	0	0.00	5	0.00	0
6	0	0.00	6	0.00	0
7	0	0.00	7	0.00	0
8	0	0.00	8	0.00	0
9	0	0.00	9	0.00	0
10	0	0.00	10	0.00	0
11	0	0.00	11	0.00	0
12	0	0.00	12	0.00	0
13	0	0.00	13	0.00	0
14	0	0.00	14	-0.80	62.55968
15	0	0.00	15	0.00	-168.553
16	0	0.00	16	0.00	109.0249
17	0	0.00	17	0.00	-42.4025
18	0	0.00	18	0.00	-44.8554
19	0	0.00	19	0.00	57.8992

20	0	0.00	20	-1.00	2.79244
21	0	0.00	21	0.80	-26.4025
22	0	0.00	22	-1.00	57.36472
23	0	0.00	23	1.80	52.0441
24	0	0.00	24	0.20	76.1008
25	0	0.00	25	4.20	-80.8236
26	0	0.00	26	3.25	-52.6189
27	0	0.00	27	-0.39	-99.8549
28	0	0.00	28	-2.79	76.05623
29	0	0.00	29	0.40	0.86983
30	0	0.00	30	0.40	-55.7886
31	0	0.00	31	1.40	77.13239
32	0	0.00	32	0.66	-13.3349
33	0	0.00	33	-1.44	-19.9602
34	0	0.00	34	1.26	28.23719
35	0	0.00	35	0.30	66.77321
36	0	0.00	36	3.39	132.9434
37	-1.134888	19.13	37	-5.22	-105.731
38	-0.100092	-7.82	38	-0.13	-47.4399
39	0.9574121	-66.87	39	0.02	-89.0174

t	α_{3t}	β_{3t}	t	α_{4t}	β_{4t}
40	-0.426805	89.75	40	0.15	159.846
41	-0.526976	-10.35	41	-0.02	-118.727
42	0.4135237	-63.84	42	-0.02	10.45276
43	0.2016514	70.81	43	-0.08	103.1212
44	2.594607	39.55	44	0.02	-57.6944
45	-0.419103	-30.76	45	0.04	5.651029
46	1.2416195	65.39	46	-0.01	90.52609
47	0.3366083	-41.79	47	-0.11	-104.809
48	-0.234485	-69.46	48	-0.20	76.95345
49	-0.377482	163.87	49	1.06	115.8017
50	0.6453441	76.82	50	-0.72	-66.8266
51	-0.210173	123.40	51	1.22	82.69102
52	-0.761385	99.96	52	0.55	87.59205
53	1.0808186	79.82	53	-1.62	-33.2987
54	-0.221289	-81.71	54	0.98	-160.065
55	-0.329737	-88.16	55	0.13	48.08387
56	-2.922308	50.83	56	0.22	6.520218
57	-0.098271	41.33	57	1.23	-23.1784
58	-0.132963	-97.72	58	0.39	11.34411
59	-0.385522	-46.26	59	0.29	9.513971
60	-0.208718	162.43	60	-0.78	184.5483
61	-0.358402	-140.19	61	1.20	-235.273
62	0.8348248	76.03	62	-0.48	259.567
63	0.2205845	115.93	63	1.36	-122.777
64	-0.826041	118.86	64	-1.28	214.969

65	0.5077959	-141.56	65	1.27	-213.727
66	1.1625981	-53.13	66	0.33	-20.3726
67	-0.17449	80.02	67	0.32	29.88477
68	-0.521423	36.24	68	0.41	7.566538
69	-0.143987	-26.28	69	1.37	1.691575
70	0.2843697	33.41	70	0.57	53.55714
71	-1.401728	153.80	71	-0.52	130.3944
72	-0.880509	229.59	72	0.26	282.9234
73	0.4312695	-70.81	73	1.34	-330.11
74	-0.395879	-207.86	74	-0.26	8.258756
75	-1.419624	33.26	75	-0.52	-57.3191
76	0.0014304	-2.59	76	0.59	44.13197
77	-0.155236	-18.83	77	-0.60	-41.1663
78	-0.695107	-23.01	78	0.41	-26.9565
79	-1.296894	-14.57	79	-0.14	54.14898
80	-2.159542	32.62	80	0.18	15.20729
81	1.7137894	8.81	81	1.49	-10.9794
82	-1.49611	-66.13	82	-0.38	20.53257
t	α_{3t}	β_{3t}	t	α_{4t}	β_{4t}
83	-2.088062	-4.64	83	-0.37	44.874
84	-0.271295	-145.89	84	1.04	-31.321
85	1.1514433	-171.48	85	0.26	-110.075
86	-0.44081	337.28	86	0.56	352.0596
87	-0.176682	188.93	87	-0.49	-98.4363
88	0.9242157	155.53	88	0.55	357.7101
89	0.4518715	-89.65	89	0.43	-293.652
90	0.4158198	1.65	90	0.29	-10.8535
91	0.2579299	49.57	91	0.31	-39.7266
92	-0.258993	4.09	92	0.38	19.91988
93	0.2953601	0.28	93	1.21	11.41409
94	0.4620569	67.96	94	-0.44	58.79331
95	0.0627543	104.95	95	-0.67	70.31007
96	0.5079427	-56.31	96	-0.01	-30.0808

Lampiran 3. Plot Korelasi Silang Variabel Input dan Output yang Telah Diputihkan

Plot korelasi silang variabel kelembaban

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
-20	29.914511	0.07586												.	**	.							
-19	-67.643399	-.17155												***	.								
-18	58.354532	0.14799												.	***	.							
-17	-0.941537	-.00239												.	.	.							
-16	-10.110976	-.02564												.	*	.							
-15	10.539343	0.02673												.	*	.							
-14	-9.128711	-.02315												.	.	.							
-13	0.011141	0.00003												.	.	.							
-12	-19.702739	-.04997												.	*	.							
-11	69.809004	0.17704												.	.	***							
-10	-40.978624	-.10392												.	**	.							
-9	-17.026565	-.04318												.	*	.							
-8	-17.706005	-.04490												.	*	.							
-7	-52.147477	-.13225												.	***	.							
-6	71.549543	0.18145												.	.	***							
-5	-33.556181	-.08510												.	**	.							
-4	42.597962	0.10803												.	.	**	.						
-3	-7.578599	-.01922												.	.	.							
-2	4.040028	0.01025												.	.	.							
-1	30.922711	0.07842												.	.	**	.						
0	19.378981	0.04915												.	.	*	.						
1	-3.176761	-.00806																	
2	42.886833	0.10876												.	.	**	.						
3	-59.025462	-.14969												.	***	.							
4	-38.864509	-.09856												.	.	**	.						
5	-7.303911	-.01852																	
6	60.348006	0.15305												.	.	.	***	.					
7	0.886478	0.00225																
8	8.777652	0.02226																
9	-32.366817	-.08208												.	.	**	.	.					
10	-54.377446	-.13790												.	***	.	.	.					
11	23.494384	0.05958												.	.	*	.	.					
12	-39.664403	-.10059												.	.	**	.	.					
13	70.482165	0.17875												.	.	.	***	.					
14	-45.649911	-.11577												.	.	**	.	.					
15	18.128188	0.04597												.	.	*	.	.					
16	-62.065978	-.15740												.	***	.	.	.					
17	0.886790	0.00225																
18	51.174326	0.12978												.	.	.	***	.					
19	45.121908	0.11443												.	.	.	**	.					
20	25.263388	0.06407												.	.	.	*	.					

Plot korelasi silang variabel tekanan

Crosscorrelations			
Lag	Covariance	Correlation	-1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
-20	-4.554469	-.05728	. *
-19	2.249970	0.02830	. *
-18	5.844263	0.07350	. *
-17	-19.266229	-.24229	*****
-16	5.303848	0.06670	. *
-15	8.702471	0.10944	. **
-14	-16.259602	-.20448	****
-13	5.795396	0.07288	. *
-12	-3.435591	-.04321	. *
-11	-2.974915	-.03741	. *
-10	-6.050177	-.07609	. **
-9	6.799402	0.08551	. **
-8	10.312130	0.12968	. ***
-7	1.414728	0.01779	. *
-6	3.906329	0.04913	. *
-5	9.383075	0.11800	. **
-4	0.558870	0.00703	. *
-3	-5.573757	-.07010	. *
-2	-6.220201	-.07822	. **
-1	1.206642	0.01517	. *
0	-21.401344	-.26914	*****
1	15.118008	0.19012	. ****
2	-11.257997	-.14158	. ***
3	1.227447	0.01544	. *
4	10.066332	0.12659	. ***
5	-4.509970	-.05672	. *
6	-7.691684	-.09673	. **
7	1.162807	0.01462	. *
8	12.806144	0.16105	. ***
9	-2.547082	-.03203	. *
10	4.723082	0.05940	. *
11	6.871551	0.08642	. **
12	-8.461663	-.10641	. **
13	2.063967	0.02596	. *
14	-5.899320	-.07419	. *
15	4.448017	0.05594	. *
16	-6.934243	-.08720	. **
17	7.159021	0.09003	. **
18	-11.257116	-.14157	. ***
19	4.681523	0.05887	. *
20	-12.216600	-.15364	. ***

"," marks two standard errors

Plot korelasi silang variabel temperatur

Crosscorrelations																								
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
-20	-20.491319	-.15167											***		.									
-19	-4.056656	-.03003										.	*		.									
-18	12.629773	0.09348										.		**	.									
-17	18.493569	0.13688										.		***	.									
-16	-12.573446	-.09306										.	**		.									
-15	-8.381834	-.06204										.	*		.									
-14	17.836975	0.13202										.		***	.									
-13	6.334445	0.04688										.		*	.									
-12	-26.546569	-.19648										****			.									
-11	-21.016649	-.15556										***			.									
-10	16.757129	0.12403										.		**	.									
-9	17.918013	0.13262										.		***	.									
-8	-8.465810	-.06266										.	*		.									
-7	-8.895764	-.06584										.	*		.									
-6	-2.228576	-.01649										.			.									
-5	3.358706	0.02486										.			.									
-4	-2.430934	-.01799										.			.									
-3	-9.360691	-.06928										.	*		.									
-2	19.472858	0.14413										.		***	.									
-1	22.093384	0.16352										.		***	.									
0	-4.587616	-.03396										.	*		.									
1	-3.059639	-.02265										.			.									
2	9.136229	0.06762										.		*	.									
3	-5.278272	-.03907										.	*		.									
4	-25.998769	-.19243										****			.									
5	24.141024	0.17868										.		****	.									
6	19.618958	0.14521										.		***	.									
7	11.424324	0.08456										.		**	.									
8	-15.305353	-.11328										.	**		.									
9	7.700456	0.05700										.		*	.									
10	13.681714	0.10127										.		**	.									
11	-12.075192	-.08937										.	**		.									
12	0.723958	0.00536										.			.									
13	16.510384	0.12220										.		**	.									
14	-13.750763	-.10178										.	**		.									
15	-32.708730	-.24209										*****			.									
16	-19.882389	-.14716										***			.									
17	-0.503577	-.00373										.			.									
18	16.255648	0.12032										.		**	.									
19	-9.634366	-.07131										.	*		.									
20	-2.161817	-.01600										.			.									

"," marks two standard errors

Plot korelasi silang variabel kecepatan

Crosscorrelations

Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
-20	-1.281671	-.00901											.		.								
-19	-9.495906	-.06676										*		.									
-18	1.755962	0.01235										.		.									
-17	5.105794	0.03590										.	*	.									
-16	-1.689661	-.01188										.		.									
-15	-10.178080	-.07156										*		.									
-14	9.462873	0.06653										.	*	.									
-13	0.510085	0.00359										.		.									
-12	4.493702	0.03159										.	*	.									
-11	-6.985298	-.04911										.	*	.									
-10	-0.020494	-.00014										.		.									
-9	8.543954	0.06007										.	*	.									
-8	-20.109951	-.14139										***		.									
-7	1.852547	0.01302										.		.									
-6	3.318768	0.02333										.		.									
-5	8.477440	0.05960										.	*	.									
-4	-18.790180	-.13211										***		.									
-3	18.633450	0.13101										.	***	.									
-2	-1.808675	-.01272										.		.									
-1	14.908507	0.10482										.	**	.									
0	-19.313155	-.13579										***		.									
1	7.848388	0.05518										.	*	.									
2	-1.116003	-.00785										.		.									
3	-2.923629	-.02056										.		.									
4	-3.003134	-.02111										.		.									
5	-1.434463	-.01009										.		.									
6	-0.132084	-.00093										.		.									
7	1.077895	0.00758										.		.									
8	-12.954130	-.09108										.	**	.									
9	4.040798	0.02841										.	*	.									
10	19.082554	0.13416										.	***	.									
11	4.406868	0.03098										.	*	.									
12	-31.614294	-.22227										****		.									
13	23.258766	0.16353										.	***	.									
14	-14.499944	-.10195										.	**	.									
15	13.617182	0.09574										.	**	.									
16	-20.085559	-.14122										.	***	.									
17	19.906345	0.13996										.	***	.									
18	-9.547080	-.06712										.	*	.									
19	-1.955972	-.01375										.		.									
20	6.602856	0.04642										.	*	.									

"," marks two standard errors

Lampiran 4. Deret *Noise* Masing-masing Deret Input

nt1	nt2	nt3	nt4
59.24	32.813	50.804	20.077
-16.64	-52.735	-51.341	29.701
60.13	-9.714	-191.384	20.843
7.94	10.232	-101.768	33.077
45.18	46.233	-253.819	-35.015
-24.70	-23.083	-83.152	1.766
63.82	46.624	-60.424	-1.333
45.18	15.046	-34.140	71.300
123.24	76.878	278.434	51.349
-1.36	16.847	-149.447	-63.903
-9.40	45.630	171.995	-11.914
99.64	116.309	91.721	29.648
-67.07	45.119	87.318	0.046
62.55	67.415	162.825	-19.421
-18.01	77.793	102.098	14.319
-9.05	-115.422	-25.880	-116.621
-88.14	-66.103	41.376	20.141
94.16	20.402	9.892	1.408
15.57	128.986	101.466	115.800
126.77	156.053	-62.655	137.193
92.57	123.366	5.578	229.154
175.13	130.066	90.546	73.508
69.47	-42.230	-49.118	53.993
-74.65	-88.747	-81.625	-48.016
83.56	-56.425	-116.730	-19.871
-89.82	18.971	-72.393	8.636
-91.73	-89.440	14.081	-50.070
9.41	69.785	61.163	12.448
162.24	101.507	207.760	83.066
-127.27	-104.144	7.087	-130.206
44.65	43.908	170.367	51.658
-63.28	-62.741	173.743	-22.948
18.57	96.549	5.069	1.387
-109.60	-190.108	19.074	-49.500
-36.50	-69.441	-9.872	-7.977
70.86	20.404	-28.832	-19.948
-17.80	-18.055	24.373	7.061
43.79	-65.916	25.271	13.882

nt1	nt2	nt3	nt4
35.77	126.147	28.545	89.549
145.96	81.997	-45.582	177.057
273.02	-154.506	-196.451	219.492
-6.27	-43.351	-167.177	117.387
-106.76	-252.020	-107.575	-153.632
-113.28	107.406	-20.944	-96.082
-175.80	17.769	9.552	-246.695
-50.06	2.924	19.512	37.499
5.68	55.377	90.354	-61.394
-50.24	26.815	84.378	27.475
8.08	-49.434	-10.897	-19.492
0.11	-120.603	-85.247	54.031
-86.21	-308.678	-270.767	-64.645
-149.92	-147.866	-81.209	-138.851
-420.79	207.410	184.752	-352.134
-69.01	212.616	86.930	-110.992
226.10	337.541	411.313	256.787
222.03	58.964	102.976	139.624
366.05	139.287	57.212	497.129
39.17	-17.885	-17.101	72.921
29.08	-38.423	-22.020	121.064
-79.80	92.187	-50.648	-50.947
-18.54	67.597	-9.674	58.593
3.76	-1.939	81.305	-7.830
61.37	146.640	57.790	52.902

Lampiran 5. Plot ACF dan PACF Deret Noise Gabungan

Autocorrelations																								
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	Std Error
0	12753.704	1.00000																						0
1	2715.095	0.21289									.				****									0.109109
2	2303.119	0.18058									.				****	.								0.113947
3	-2468.170	-.19353									****					.								0.117304
4	-3581.645	-.28083									*****					.								0.121045
5	-2959.801	-.23207									*****					.								0.128568
6	-780.792	-.06122									.	*			.									0.133462
7	815.317	0.06393									.	*			.									0.133796
8	1352.593	0.10605									.				**	.								0.134159
9	1727.906	0.13548									.				***	.								0.135153
10	-494.881	-.03880									.	*			.									0.136761
11	-246.689	-.01934									.				.									0.136892
12	-5355.547	-.41992									*****					.								0.136924
13	-446.999	-.03505									.	*			.									0.151482
14	-2347.764	-.18408									.	****			.									0.151578
15	1053.213	0.08258									.				**	.								0.154217
16	1430.727	0.11218									.				**	.								0.154742
17	1622.133	0.12719									.				***	.								0.155707
18	1027.353	0.08055									.				**	.								0.156939
19	1387.855	0.10882									.				**	.								0.157431
20	1181.554	0.09264									.				**	.								0.158324
21	-164.274	-.01288									.				.									0.158968
22	-417.942	-.03277									.	*			.									0.158980
23	-1612.325	-.12642									.	***			.									0.159060
24	-423.398	-.03320									.	*			.									0.160252
25	-3003.513	-.23550									*****				.									0.160334
26	2107.795	0.16527									.				***	.								0.164400
27	-140.287	-.01100									.				.									0.166367
28	1214.193	0.09520									.				**	.								0.166375
29	922.684	0.07235									.				*	.								0.167022
30	-435.524	-.03415									.	*			.									0.167395
31	-1733.073	-.13589									.	***			.									0.167478
32	-1371.236	-.10752									.	**			.									0.168786
33	-1173.422	-.09201									.	**			.									0.169599
34	-813.372	-.06378									.	*			.									0.170192
35	1611.971	0.12639									.				***	.								0.170476
36	797.746	0.06255									.	*			.									0.171588
37	2064.255	0.16186									.				***	.								0.171860
38	-899.423	-.07052									.	*			.									0.173665
39	-99.366346	-.00779									.				.									0.174005
40	-628.005	-.04924									.	*			.									0.174009

"." marks two standard errors

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
1	0.21289										.		****									
2	0.14168										.		***.									
3	-0.27438									*****				.								
4	-0.24758									*****				.								
5	-0.06189									.	*			.								
6	0.06283									.		*		.								
7	0.03124									.		*		.								
8	-0.04000									.	*			.								
9	0.03104									.		*		.								
10	-0.09667									.	**			.								
11	0.00897									.				.								
12	-0.41011								*****					.								
13	0.15111								.				***.									
14	-0.08115								.	**			.									
15	-0.04909								.	*			.									
16	-0.04297								.	*			.									
17	-0.02107								.				.									
18	0.02747								.		*		.									
19	0.13506								.		***.											
20	0.10261								.		**.			.								
21	-0.01779								.				.									
22	-0.08416								.	**			.									
23	0.00155								.				.									
24	-0.13346								.	***			.									
25	-0.18608								****				.									
26	0.19805								.		****											
27	-0.01938								.				.									
28	-0.07138								.	*			.									
29	0.04923								.		*		*									
30	-0.02998								.	*			.									
31	-0.04410								.	*			.									
32	0.05749								.		*		*									
33	-0.05177								.	*			.									
34	-0.12580								.	***			.									
35	0.07467								.		*		.									
36	-0.06484								.	*			.									
37	-0.17487								.	***			.									
38	0.07336								.		*		*									
39	-0.06751								.	*			.									
40	0.09157								.		**.		.									

Autocorrelation Check for White Noise

Lampiran 6. Output SAS Hasil Estimasi Parameter

Hasil Estimasi Parameter Model *ARIMA* untuk Kelembaban Udara

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.90054	0.08304	10.84	<.0001	12
AR1,1	0.25820	0.10788	2.39	0.0190	1
AR1,2	0.25266	0.10862	2.33	0.0225	2

Variance Estimate 16.12906

Std Error Estimate 4.016101

AIC 474.8991

SBC 482.1916

Number of Residuals 84

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.71	3	0.8716	0.002	-0.015	-0.032	0.045	0.010	
12	3.67	9	0.9318	0.000	-0.046	0.029	-0.090	0.081	
18	8.72	15	0.8919	0.138	0.106	-0.055	0.089	-0.006	
24	12.03	21	0.9387	0.003	0.087	-0.106	0.015	-0.073	-

Hasil Estimasi Parameter Model *ARIMA* untuk Tekanan Udara

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.47137	0.19701	2.39	0.0190	1
MA2,1	0.64816	0.09329	6.95	<.0001	12
AR1,1	0.78800	0.13709	5.75	<.0001	1

Variance Estimate 0.761203
 Std Error Estimate 0.87247
 AIC 218.407
 SBC 225.6994
 Number of Residuals 84

- AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.51	3	0.0572	-0.026	0.035	0.076	0.031	-0.256	
12	11.27	9	0.2573	0.015	-0.088	0.134	0.074	-0.084	
18	12.92	15	0.6082	0.014	-0.048	-0.018	0.015	0.075	-
24	20.64	21	0.4813	0.093	0.007	-0.089	-0.118	0.178	-
30	25.67	27	0.5370	0.024	0.060	-0.098	-0.133	0.031	-
36	32.75	33	0.4795	-0.119	0.087	0.098	-0.017	0.134	

Hasil Estimasi Parameter Model *ARIMA* untuk Temperatur

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.62572	0.08683	-7.21	<.0001	2
AR1,1	-0.50689	0.11278	-4.49	<.0001	12
AR2,1	-0.49954	0.11977	-4.17	<.0001	24

Variance Estimate 1.960004
 Std Error Estimate 1.400001
 AIC 297.8543
 SBC 305.1468
 Number of Residuals 84

- AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Chi- Pr >

	Lag	Square	DF	ChiSq	-----Autocorrelations-----					
-										
0.110	6	4.23	3	0.2374	0.025	0.048	-0.013	0.022	0.175	-
0.109	12	10.45	9	0.3153	-0.129	-0.021	-0.150	0.004	-0.113	-
0.021	18	18.19	15	0.2530	0.064	-0.059	0.234	0.102	-0.029	
0.058	24	23.68	21	0.3086	0.074	0.091	0.150	-0.006	0.090	-
0.022	30	27.66	27	0.4286	-0.099	0.050	-0.108	-0.059	-0.059	-
0.270	36	44.13	33	0.0933	0.015	-0.047	-0.173	0.077	0.013	

Hasil Estimasi Parameter Model *ARIMA* untuk Kecepatan Angin

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.94537	0.07895	11.97	<.0001	12
AR1,1	0.79874	0.07088	11.27	<.0001	1
Variance Estimate			1.551432		
Std Error Estimate			1.245565		
AIC			277.2484		
SBC			282.1101		
Number of Residuals			84		

- AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

	To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-										
0.034	6	5.57	4	0.2335	-0.073	0.040	-0.175	0.126	0.086	
0.134	12	10.47	10	0.4006	-0.004	0.009	0.131	0.107	0.057	-
0.066	18	15.92	16	0.4588	0.139	-0.131	0.104	0.031	-0.009	
0.020	24	18.78	22	0.6589	0.035	0.023	-0.006	-0.016	0.148	-
0.010	30	24.27	28	0.6672	0.114	0.001	0.121	-0.116	0.047	
0.069	36	26.87	34	0.8026	0.071	0.058	0.012	0.069	-0.015	

Hasil Estimasi Parameter Model *ARIMA* untuk Deret *Noise* Kelembaban udara

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.63792	0.11164	5.71	<.0001	12
AR1,1	0.24247	0.10779	2.25	0.0272	1

Variance Estimate 8970.321
 Std Error Estimate 94.71178
 AIC 1004.898
 SBC 1009.76
 Number of Residuals 84
 * AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-									
6	6.82	4	0.1460	-0.038	0.194	-0.128	-0.101	-0.105	-
0.015									
12	10.07	10	0.4341	0.066	0.063	0.092	-0.067	0.062	-
0.092									
18	14.67	16	0.5488	-0.047	-0.035	0.067	0.161	0.092	
0.031									
24	17.71	22	0.7229	0.061	0.105	-0.036	0.000	0.007	
0.101									
30	33.88	28	0.2047	-0.225	0.233	-0.067	0.129	0.058	-
0.014									
36	40.53	34	0.2043	-0.048	-0.037	-0.083	-0.076	0.169	
0.026									

Hasil Estimasi Parameter Model ARIMA untuk Deret *Noise* Tekanan udara

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.30573	0.10746	-2.84	0.0056	1
AR1,1	-0.61053	0.11088	-5.51	<.0001	12

Variance Estimate 8887.078
 Std Error Estimate 94.2713
 AIC 1004.115
 SBC 1008.977
 Number of Residuals 84
 * AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-									
6	8.21	4	0.0842	0.054	0.155	-0.104	-0.159	-0.166	-
0.034									
12	9.90	10	0.4489	0.052	0.010	0.073	-0.027	-0.016	-
0.091									
18	13.61	16	0.6281	-0.091	-0.018	0.027	0.120	0.098	
0.042									
24	20.28	22	0.5655	0.096	0.130	0.039	-0.020	0.017	-
0.171									
30	33.85	28	0.2059	-0.239	0.166	-0.055	0.109	0.095	
0.006									
36	41.08	34	0.1882	-0.068	-0.041	-0.095	-0.127	0.118	
0.069									

Hasil Estimasi Parameter Model *ARIMA* untuk Deret *Noise* Temperatur

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.61765	0.11215	5.51	<.0001	12
AR1,1	0.29960	0.10570	2.83	0.0058	1

Variance Estimate 8486.775
 Std Error Estimate 92.12369
 AIC 1000.244
 SBC 1005.105
 Number of Residuals 84
 * AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Chi- Pr >

	Lag	Square	DF	ChiSq	-----Autocorrelations-----					
-										
0.016	6	6.40	4	0.1712	-0.036	0.173	-0.135	-0.099	-0.110	-
0.092	12	9.02	10	0.5303	0.078	0.054	0.072	-0.058	0.032	-
0.021	18	12.85	16	0.6840	-0.045	-0.017	0.059	0.152	0.082	
0.083	24	15.54	22	0.8380	0.058	0.101	-0.035	0.040	-0.016	
0.012	30	34.27	28	0.1921	-0.262	0.237	-0.081	0.128	0.055	-
0.062	36	41.00	34	0.1905	-0.052	-0.041	-0.084	-0.105	0.142	

Hasil Estimasi Parameter Model *ARIMA* untuk Deret *Noise* Kecepatan Angin

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.30507	0.10748	-2.84	0.0057	1
AR1,1	-0.61053	0.11092	-5.50	<.0001	12

Variance Estimate 8891.118
 Std Error Estimate 94.29272
 AIC 1004.153
 SBC 1009.015
 Number of Residuals 84
 * AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

	To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-										
0.034	6	8.25	4	0.0828	0.054	0.154	-0.106	-0.159	-0.165	-
0.091	12	9.96	10	0.4438	0.053	0.009	0.073	-0.027	-0.016	-
0.043	18	13.70	16	0.6213	-0.091	-0.017	0.028	0.121	0.098	
0.170	24	20.30	22	0.5643	0.093	0.129	0.039	-0.020	0.017	-
0.008	30	33.88	28	0.2049	-0.239	0.167	-0.056	0.110	0.093	
0.069	36	41.11	34	0.1871	-0.069	-0.041	-0.095	-0.127	0.118	

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	-0.34937	0.10591	-3.30	0.0014	1	y	0
AR1,1	-0.72107	0.10643	-6.77	<.0001	12	y	0
NUM1	-34.44396	9.51806	-3.62	0.0005	0	x2	0

7829.46

88.48424

994.4413

1001.734

84

- AIC and SBC do not include log determinant.

	To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
0.030	6	6.16	4	0.1873	0.056	0.126	-0.112	-0.080	-0.172	-
0.096	12	9.41	10	0.4939	0.113	0.055	0.081	-0.033	-0.028	-
0.042	18	12.06	16	0.7401	-0.082	-0.074	0.033	0.098	0.027	-
0.138	24	15.60	22	0.8353	0.092	0.016	-0.011	-0.045	-0.004	-
0.067	30	29.88	28	0.3688	-0.222	0.192	-0.088	0.122	0.030	
0.082	36	35.10	34	0.4155	-0.103	0.019	-0.073	-0.072	0.091	

To	Chi-		Pr >	
Lag	Square	DF	ChiSq	-----Crosscorrelations-----

0.161	5	9.03	5	0.1080	0.048	0.129	-0.129	0.150	0.153	-
0.029	11	14.06	11	0.2298	-0.073	0.095	0.077	-0.002	0.197	
0.097	17	15.56	17	0.5554	-0.038	0.073	-0.021	0.020	-0.030	
0.053	23	27.11	23	0.2511	-0.187	0.077	-0.157	-0.019	-0.262	
0.080	29	29.09	29	0.4605	0.055	0.039	0.062	0.013	-0.092	-
0.017	35	37.64	35	0.3492	0.167	-0.104	0.154	0.141	0.139	

Hasil Estimasi Parameter Model Fungsi Transfer untuk Temperatur

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	0.68455	0.10863	6.30	<.0001	12	y	0
AR1,1	0.34422	0.10800	3.19	0.0021	1	y	0
NUM1	-12.65100	5.64768	-2.24	0.0280	0	x3	4

Variance Estimate 8191.986
Std Error Estimate 90.50959
AIC 950.8454
SBC 957.9915
Number of Residuals 80

- AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
-										
0.015	6	3.06	4	0.5472	-0.023	0.114	-0.097	-0.084	-0.076	-
0.071	12	6.81	10	0.7435	0.066	0.085	0.078	-0.133	-0.005	-
0.023	18	10.88	16	0.8170	-0.049	-0.035	0.047	0.166	0.076	
0.110	24	13.87	22	0.9062	0.052	0.098	0.012	0.013	0.041	
0.043	30	25.00	28	0.6280	-0.233	0.140	-0.085	0.077	0.052	-
0.023	36	39.61	34	0.2341	-0.032	-0.067	-0.060	-0.188	0.237	

Crosscorrelation Check of Residuals with Input x3

Crosscorrelation Check of Residuals with Input x4

	To Lag	Chi- Square	DF	Pr > ChiSq	-----Crosscorrelations-----				
-									
0.243	5	6.73	5	0.2413	-0.052	0.191	0.016	0.104	-0.051
0.022	11	10.19	11	0.5130	-0.004	0.025	0.230	0.059	0.012 -
0.067	17	15.07	17	0.5907	0.078	-0.046	0.207	0.004	0.161 -
0.218	23	18.92	23	0.7058	0.027	0.048	0.038	-0.010	-0.110 -
0.022	29	22.55	29	0.7967	0.109	0.169	0.083	0.108	-0.033 -
0.205	35	29.82	35	0.7163	-0.071	-0.004	-0.131	0.047	0.234

Hasil Estimasi Parameter Model Fungsi Transfer Multivariat

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	-0.36175	0.12030	-3.01	0.0037	1	y	0
AR1,1	-0.86989	0.10655	-8.16	<.0001	12	y	0
NUM1	-2.33515	1.95876	-1.19	0.2375	0	x1	3
NUM2	-41.92147	9.16962	-4.57	<.0001	0	x2	0
NUM3	-10.34472	4.46244	-2.32	0.0235	0	x3	4
NUM4	-13.38805	5.39095	-2.48	0.0156	0	x4	12

Variance Estimate 7130.984

Std Error Estimate 84.44515

AIC 848.8611

SBC 862.5211

Number of Residuals 72

* AIC and SBC do not include log determinant.

Hasil Estimasi Parameter Model Fungsi Transfer Multivariat

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	-0.34972	0.11861	-2.95	0.0044	1	y	0
AR1,1	-0.88011	0.10354	-8.50	<.0001	12	y	0

NUM1	-43.22914	9.11182	-4.74	<.0001	0	x2	0
NUM2	-10.39131	4.47724	-2.32	0.0233	0	x3	4
NUM3	-13.63130	5.37499	-2.54	0.0135	0	x4	12

Variance Estimate 7175.252
Std Error Estimate 84.70686
AIC 848.3894
SBC 859.7727

Number of Residuals 72

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-									
6	4.66	4	0.3238	0.063	0.169	-0.069	-0.129	-0.081	-
0.003									
12	13.24	10	0.2108	0.263	0.039	0.147	-0.063	-0.062	-
0.058									
18	17.49	16	0.3546	-0.102	0.023	-0.025	0.160	-0.064	-
0.061									
24	22.42	22	0.4348	0.089	-0.058	-0.032	-0.121	0.061	-
0.124									
30	31.89	28	0.2790	-0.165	0.134	-0.148	0.092	-0.063	
0.037									
36	47.14	34	0.0664	-0.173	-0.066	-0.075	-0.044	0.256	-
0.046									

Crosscorrelation Check of Residuals with Input x2

To Lag	Chi- Square	DF	Pr > ChiSq	-----Crosscorrelations-----					
-									
5	6.82	5	0.2346	0.094	0.159	-0.097	0.152	-0.011	-
0.167									
11	16.75	11	0.1154	-0.133	0.175	-0.024	-0.004	0.298	-
0.010									
17	17.75	17	0.4048	-0.035	0.100	0.028	-0.031	-0.030	
0.001									
23	26.84	23	0.2628	-0.180	0.078	-0.149	-0.019	-0.256	
0.003									
29	28.34	29	0.4997	-0.006	0.040	0.116	0.053	0.011	-
0.054									
35	34.31	35	0.5011	0.158	-0.183	0.095	0.027	0.106	
				0.059					

Crosscorrelation Check of Residuals with Input x3

To Chi- Pr >

Lag	Square	DF	ChiSq	-----Crosscorrelations-----					
-									
5	9.04	5	0.1076	0.089	0.174	-0.110	0.032	-0.217	
0.185									
11	14.09	11	0.2279	-0.115	-0.015	0.060	0.033	0.020	-
0.236									
17	22.16	17	0.1786	-0.196	-0.013	0.095	-0.116	0.235	
0.048									
23	24.68	23	0.3670	-0.030	-0.039	0.143	0.096	0.039	
0.058									
29	35.72	29	0.1818	0.135	-0.048	-0.176	-0.112	-0.303	
0.080									
35	39.39	35	0.2797	-0.091	0.136	-0.092	-0.066	-0.118	
0.016									

Crosscorrelation Check of Residuals with Input x4

To Lag	Chi-Square	DF	Pr > ChiSq	-----Crosscorrelations-----					
-									
5	4.08	5	0.5385	-0.020	0.141	-0.001	-0.012	-0.069	
0.207									
11	6.24	11	0.8571	-0.103	0.063	0.112	0.049	0.079	
0.013									
17	10.83	17	0.8651	0.001	-0.088	0.189	-0.064	0.168	
0.027									
23	17.03	23	0.8079	0.018	0.042	0.113	0.094	-0.235	-
0.157									
29	22.78	29	0.7865	0.062	0.105	0.140	0.197	-0.093	-
0.118									
35	26.84	35	0.8369	-0.081	-0.058	-0.152	0.060	0.152	
0.089									

Hasil Rmalan curah hujan tahun 2010 dan 2011

97	46.3177	92.7241	-135.4182	228.0535	.	.
98	182.2573	98.0710	-9.9583	374.4729	.	.
99	218.8837	98.5214	25.7853	411.9822	.	.
100	80.0693	98.8001	-113.5753	273.7139	.	.
101	71.8275	100.0362	-124.2398	267.8948	.	.
102	6.4120	100.1421	-189.8629	202.6869	.	.
103	0.3704	100.6204	-196.8420	197.5828	.	.
104	4.9952	100.6610	-192.2968	202.2872	.	.
105	5.7414	100.6862	-191.6000	203.0828	.	.
106	13.2327	100.7019	-184.1393	210.6048	.	.
107	78.0848	100.7116	-119.3063	275.4759	.	.
108	142.5074	100.7176	-54.8956	339.9103	.	.
109	65.0856	103.6115	-137.9892	268.1605	.	.
110	428.9322	104.6697	223.7833	634.0811	.	.
111	384.5388	105.2992	178.1563	590.9214	.	.
112	458.5984	105.6976	251.4350	665.7618	.	.
113	96.6934	106.1928	-111.4407	304.8275	.	.
114	97.0103	106.3529	-111.4375	305.4581	.	.
115	11.6876	106.5492	-197.1449	220.5201	.	.
116	17.2063	106.6138	-191.7529	226.1654	.	.

117	50.4760	106.6549	-158.5636	259.5157	.	.
118	107.1303	106.6810	-101.9606	316.2212	.	.
119	154.3717	106.6976	-54.7518	363.4952	.	.
120	235.2393	106.7082	26.0950	444.3835	.	.

Lampiran 7. Sintak Program SAS 9.1.3

```
data multi;
input x1 x2 x3 x4 y;
label x1 ='kelembaban'
      x2 ='tekanan'
      x3='temperatur'
      x4='kec_angin'
      y='hujan';
datalines;
```

85	1009.8	26.5	2	162
87	1010.3	26.2	2	207
83	1009.6	27.1	2	296
83	1009.4	27.1	2	52
80	1010.4	27.2	2	90
78	1011.2	26.2	2	84
75	1010.8	25.9	2	6
73	1010.5	31.1	3	2
72	1012.8	26.2	3	30
73	1012.1	33.2	3	1
80	1010.9	27.8	3	21
84	1010.9	27.8	3	70
84	1010.8	26.6	3	130
84	1009.2	26.4	2	244
83	1010	27	2	157
79	1010	26.6	2	50
79	1010.4	24.1	2	46
82	1011.2	26.4	2	4
66	1013.3	23.2	2	0
65	1013.6	25.3	2	0
72	1013.7	25.8	3	2
78	1012.6	25.8	2	36
84	1011.2	31.1	4	101
85	1010.7	27.8	4	210
85	1010.7	28.8	8	161
86	1010.2	26.4	10	157
86	1009.9	26.6	8	147
79	1011	28.1	4	15
82	1010.8	27.1	4	59
79	1011.9	25.9	4	1
78	1010.7	26.2	5	20
64	1012.6	25.4	6	0

73	1011.8	26.8	4	7
72	1011.9	27.5	5	14
81	1009.9	27.6	5	101
85	1010.2	26.7	8	271
85	1009.8	26.5	2	180.4
87	1010.3	26.2	2	174.8
83	1009.6	27.1	2	166.6
83	1009.4	27.1	2	118.6
80	1010.4	27.2	2	22.2
78	1011.2	26.2	2	34.8
75	1012.5	25.9	2	77.2
73	1013.1	31.1	3	0.6
72	1013.8	26.2	3	32
72	1012.1	33.2	3	97.8
80	1010.9	27.8	3	0
72	1010.9	27.8	3	141.6
87	1009.2	26.4	4	292.8
86	1009.6	26.8	3	142.6
90	1008.9	26.6	4	387.6
87	1009.6	26.5	4	231.6
85	1010.9	26.6	2	191.4
81	1011.6	25.6	3	0
79	1012.9	24.9	3	0
74	1013.1	25.1	4	0
73	1013.8	25.7	5	3
72	1013.7	27.5	5	0.4
72	1011.2	29	5	30.8
83	1009.7	27.5	4	278
81	1010.8	27	5	57
82	1010.2	27.3	4	377
84	1008.9	26.6	5	294
86	1010	27	3	289
80	1010.5	27.5	4	55
79	1009.2	26.4	4	22
78	1011.5	25.7	4	2
75	1012.3	25.5	5	3
73	1012.4	26	6	29
75	1011.2	27.5	6	64
82	1010.2	26.8	5	203
80	1008.1	26.4	5	524
83	1009	26.3	6	145.8
84	1008	25.8	5	210.8
85	1009	25.7	4	220
79	1009	26.8	4	70.8
75	1011	26.3	3	41.6
73	1011	25.6	3.3	3.6
60	1012	24.4	3	13.2
69	1012	25.7	4	20
66	1012	27	5.4	30
71	1011	27.5	4.6	34.7

81	1009	26.3	4	101.2
81	1009	25.9	5	143.9
80	1009	26.2	5	44.2
83	1008	25.7	5	473.9
78	1010	26.7	4	385.9
77	1009	27.3	4	519.3
78	1009	26.8	4	145.1
73	1011	26.6	4	100.9
60	1012	25.2	4	0
68	1012	25.4	5	15
66	1012	26.8	6	47.8
77	1012.1	27.8	5	88.3
75	1009.5	27.9	4	171.9
80	1010.4	27.5	4	199.9

```

;
identify var=x1(12) nlags=20;
run;
estimate p=(1 2) q=(12) noconstant;
run;
forecast out=a printall;
run;
identify var=x2(12) nlags=40;
run;
estimate p=(1) q=(1)(12) noconstant;
run;
forecast out=b printall;
run;
identify var=x3(12) nlags=40;
run;
estimate p=(12 24) q=(2) noconstant;
run;
forecast out=c printall;
run;
identify var=x4(12) nlags=40;
run;
estimate p=(1) q=(12) noconstant;
run;
forecast out=d printall;
run;
identify var=y(12) crosscorr=(x1(12) x2(12) x3(12) x4(12)) nlags=40;
run;
estimate p=(12) q=(1) input=(3$ (0) /(0)x1) input=(0$ (0) /(0)x2)
input=(4$ (0) /(0)x3) input=(12$ (0) /(0)x4) noconstant plot;
run;
forecast out=h printall;
run;
proc arima data= h;
identify var=residual;
run;
proc univariate data=h normal plot;

```

```
var residual;
run;
```

```
data kecepatan;
input x4 y;
label x4='tekanan'
      y='hujan';
cards;
```

```
2      162
2      207
2      296
2      52
2      90
2      84
2      6
3      2
3      30
3      1
3      21
3      70
3      130
2      244
2      157
2      50
2      46
2      4
2      0
2      0
3      2
2      36
4      101
4      210
8      161
10     157
8      147
4      15
4      59
4      1
5      20
6      0
4      7
5      14
5      101
8      271
2      180.4
2      174.8
2      166.6
2      118.6
```

2	22.2
2	34.8
2	77.2
3	0.6
3	32
3	97.8
3	0
3	141.6
4	292.8
3	242.6
4	387.6
4	231.6
2	191.4
3	0
3	0
4	0
5	3
5	0.4
5	30.8
4	278
5	57
4	377
5	294
3	289
4	55
4	22
4	2
5	3
6	29
6	64
5	203
5	524
6	145.8
5	210.8
4	220
4	70.8
3	41.6
3.3	3.6
3	13.2
4	20
5.4	30
4.6	34.7
4	101.2
5	143.9
5	44.2
5	473.9
4	385.9
4	519.3
4	145.1
4	100.9

4	0
5	15
6	47.8
5	88.3
4	171.9
4	199.9

```

;
proc arima data = kecepatan out=out1;
identify var=x4(12) nlags=20;
run;
estimate p=(1) q=(12) noconstant;
run;
identify var=y(12) crosscorr=(x4(12)) nlags=40;
run;
estimate p=(12) q=(1) input=(12$(0)/(0)x4) noconstant plot;
run;
forecast out=h printall;
run;
data error;
set h;
at=residual;
at2=residual*residual;
run;
proc arima data=error;
identify var=at2;
run;
proc autoreg data=error;
model at=/archtest dwprob normal noint;
run;

```

```

data temperatur;
input x3 y;
label x3='temperatur'
      y='hujan';
cards;

```

26.5	162
26.2	207
27.1	296
27.1	52
27.2	90
26.2	84
25.9	6
31.1	2
26.2	30
33.2	1
27.8	21
27.8	70

26.6	130
26.4	244
27	157
26.6	50
24.1	46
26.4	4
23.2	0
25.3	0
25.8	2
25.8	36
31.1	101
27.8	210
28.8	161
26.4	157
26.6	147
28.1	15
27.1	59
25.9	1
26.2	20
25.4	0
26.8	7
27.5	14
27.6	101
26.7	271
26.5	180.4
26.2	174.8
27.1	166.6
27.1	118.6
27.2	22.2
26.2	34.8
25.9	77.2
31.1	0.6
26.2	32
33.2	97.8
27.8	0
27.8	141.6
26.4	292.8
26.8	242.6
26.6	387.6
26.5	231.6
26.6	191.4
25.6	0
24.9	0
25.1	0
25.7	3
27.5	0.4
29	30.8
27.5	278
27	57
27.3	377

26.6	294
27	289
27.5	55
26.4	22
25.7	2
25.5	3
26	29
27.5	64
26.8	203
26.4	524
26.3	145.8
25.8	210.8
25.7	220
26.8	70.8
26.3	41.6
25.6	3.6
24.4	13.2
25.7	20
27	30
27.5	34.7
26.3	101.2
25.9	143.9
26.2	44.2
25.7	473.9
26.7	385.9
27.3	519.3
26.8	145.1
26.6	100.9
25.2	0
25.4	15
26.8	47.8
27.8	88.3
27.9	171.9
27.5	199.9

```

;
proc arima data = temperatur out=out1;
  identify var=x3(12) nlags=50;
run;
estimate p=(12)(24) q=(2) noconstant;
run;
identify var=y(12) crosscorr=(x3(12)) nlags=50;
run;
estimate p=(1) q=(12) input=(4$ (0) /(0)x3) noconstant plot;
run;
forecast out=h printall;
run;
data error;
set h;
at=residual;

```

```

at2=residual*residual;
run;
proc arima data=error;
identify var=at2;
run;
proc autoreg data=error;
model at=/archtest dwprob normal noint;
run;

```

```

data tekanan;
input x2 y;
label x2='tekanan'
      y='hujan';
cards;

```

```

1009.8 162
1010.3 207
1009.6 296
1009.4 52
1010.4 90
1011.2 84
1010.8 6
1010.5 2
1012.8 30
1012.1 1
1010.9 21
1010.9 70
1010.8 130
1009.2 244
1010 157
1010 50
1010.4 46
1011.2 4
1013.3 0
1013.6 0
1013.7 2
1012.6 36
1011.2 101
1010.7 210
1010.7 161
1010.2 157
1009.9 147
1011 15
1010.8 59
1011.9 1
1010.7 20
1012.6 0
1011.8 7
1011.9 14

```

1009.9 101
 1010.2 271
 1009.8 180.4
 1010.3 174.8
 1009.6 166.6
 1009.4 118.6
 1010.4 22.2
 1011.2 34.8
 1012.5 77.2
 1013.1 0.6
 1013.8 32
 1012.1 97.8
 1010.9 0
 1010.9 141.6
 1009.2 292.8
 1009.6 242.6
 1008.9 387.6
 1009.6 231.6
 1010.9 191.4
 1011.6 0
 1012.9 0
 1013.1 0
 1013.8 3
 1013.7 0.4
 1011.2 30.8
 1009.7 278
 1010.8 57
 1010.2 377
 1008.9 294
 1010 289
 1010.5 55
 1009.2 22
 1011.5 2
 1012.3 3
 1012.4 29
 1011.2 64
 1010.2 203
 1008.1 524
 1009 145.8
 1008 210.8
 1009 220
 1009 70.8
 1011 41.6
 1011 3.6
 1012 13.2
 1012 20
 1012 30
 1011 34.7
 1009 101.2
 1009 143.9

```

1009 44.2
1008 473.9
1010 385.9
1009 519.3
1009 145.1
1011 100.9
1012 0
1012 15
1012 47.8
1012.1 88.3
1009.5 171.9
1010.4 199.9

```

```

;
proc arima data = tekanan out=out1;
identify var=x2(12) nlags=40;
run;
estimate p=(1) q=(1)(12) noconstant;
run;
identify var=y(12) crosscorr=(x2(12)) nlags=40;
run;
estimate p=(12) q=(1) input=(0$(0) /(0)x2) noconstant plot;
run;
forecast out=h printall;
run;
data error;
set h;
at=residual;
at2=residual*residual;
run;
proc arima data=error;
identify var=at2;
run;
proc autoreg data=error;
model at=/archtest dwprob normal noint;
run;

```

```

data kelembaban;
input x1 y;
label x1='kelembaban'
      y='hujan';
cards;
85 162
87 207
83 296
83 52
80 90
78 84
75 6
73 2

```

72	30
73	1
80	21
84	70
84	130
84	244
83	157
79	50
79	46
82	4
66	0
65	0
72	2
78	36
84	101
85	210
85	161
86	157
86	147
79	15
82	59
79	1
78	20
64	0
73	7
72	14
81	101
85	271
85	180.4
87	174.8
83	166.6
83	118.6
80	22.2
78	34.8
75	77.2
73	0.6
72	32
72	97.8
80	0
72	141.6
87	292.8
86	142.6
90	387.6
87	231.6
85	191.4
81	0
79	0
74	0
73	3
72	0.4

72	30.8
83	278
81	57
82	377
84	294
86	289
80	55
79	22
78	2
75	3
73	29
75	64
82	203
80	524
83	145.8
84	210.8
85	220
79	70.8
75	41.6
73	3.6
60	13.2
69	20
66	30
71	34.7
81	101.2
81	143.9
80	44.2
83	473.9
78	385.9
77	519.3
78	145.1
73	100.9
60	0
68	15
66	47.8
77	88.3
75	171.9
80	199.9

```

;
proc arima data = kelembaban out=out1;
  identify var=x1(12) nlags=20;
run;
estimate p=(1) q=(12) noconstant;
run;
identify var=y(12) crosscorr=(x1(12)) nlags=40;
run;
estimate p=(1) q=(12) input=(3$ (0) /(0)x1) noconstant plot ;
run;
forecast out=h printall;

```




```
run;  
data error;  
set h;  
at=residual;  
at2=residual*residual;  
run;  
proc arima data=error;  
identify var=at2;  
run;  
proc autoreg data=error;  
model at=/archtest dwprob normal noint;  
run;
```

Lampiran 8. Tabel Distribusi Chi-Square

TABLE C: Chi-Square distributions

cum probability	0.025	0.80	0.90	0.95	0.975	0.99	0.995	0.999	0.9995
right tail	0.975	0.2	0.1	0.05	0.025	0.01	0.005	0.001	0.0005
df									
1	0.00098	1.64	2.71	3.84	5.02	6.63	7.88	10.83	12.12
2	0.051	3.22	4.61	5.99	7.38	9.21	10.60	13.82	15.20
3	0.216	4.64	6.25	7.81	9.35	11.34	12.84	16.27	17.73
4	0.48	5.99	7.78	9.49	11.14	13.28	14.86	18.47	20.00
5	0.83	7.29	9.24	11.07	12.83	15.09	16.75	20.51	22.11
6	1.24	8.56	10.64	12.59	14.45	16.81	18.55	22.46	24.10
7	1.69	9.80	12.02	14.07	16.01	18.48	20.28	24.32	26.02
8	2.18	11.03	13.36	15.51	17.53	20.09	21.95	26.12	27.87
9	2.70	12.24	14.68	16.92	19.02	21.67	23.59	27.88	29.67
10	3.25	13.44	15.99	18.31	20.48	23.21	25.19	29.59	31.42
11	3.82	14.63	17.28	19.68	21.92	24.73	26.76	31.26	33.14
12	4.40	15.81	18.55	21.03	23.34	26.22	28.30	32.91	34.82
13	5.01	16.98	19.81	22.36	24.74	27.69	29.82	34.53	36.48
14	5.63	18.15	21.06	23.68	26.12	29.14	31.32	36.12	38.11
15	6.26	19.31	22.31	25.00	27.49	30.58	32.80	37.70	39.72
16	6.91	20.47	23.54	26.30	28.85	32.00	34.27	39.25	41.31
17	7.56	21.61	24.77	27.59	30.19	33.41	35.72	40.79	42.88
18	8.23	22.76	25.99	28.87	31.53	34.81	37.16	42.31	44.43
19	8.91	23.90	27.20	30.14	32.85	36.19	38.58	43.82	45.97
20	9.59	25.04	28.41	31.41	34.17	37.57	40.00	45.31	47.50
21	10.28	26.17	29.62	32.67	35.48	38.93	41.40	46.80	49.01
22	10.98	27.30	30.81	33.92	36.78	40.29	42.80	48.27	50.51
23	11.69	28.43	32.01	35.17	38.08	41.64	44.18	49.73	52.00
24	12.40	29.55	33.20	36.42	39.36	42.98	45.56	51.18	53.48
25	13.12	30.68	34.38	37.65	40.65	44.31	46.93	52.62	54.95
30	16.79	36.25	40.26	43.77	46.98	50.89	53.67	59.70	62.16
40	24.43	47.27	51.81	55.76	59.34	63.69	66.77	73.40	76.10
50	32.36	58.16	63.17	67.50	71.42	76.15	79.49	86.66	89.56
60	40.48	68.97	74.40	79.08	83.30	88.38	91.95	99.61	102.7
80	57.15	90.41	96.58	101.9	106.6	112.3	116.3	124.8	128.3
100	74.22	111.7	118.5	124.3	129.6	135.8	140.2	149.4	153.2



df	α					
	0,25	0,1	0,05	0,025	0,01	0,005
1	1,000	3,078	6,314	12,706	31,821	63,657
2	0,816	1,886	2,920	4,303	6,965	9,925
3	0,765	1,638	2,353	3,182	4,541	5,841
4	0,741	1,533	2,132	2,776	3,747	4,604
5	0,727	1,476	2,015	2,571	3,365	4,032
6	0,718	1,440	1,943	2,447	3,143	3,707
7	0,711	1,415	1,895	2,365	2,998	3,499
8	0,706	1,397	1,860	2,306	2,896	3,355
9	0,703	1,383	1,833	2,262	2,821	3,250
10	0,700	1,372	1,812	2,228	2,764	3,169
11	0,697	1,363	1,796	2,201	2,718	3,106
12	0,695	1,356	1,782	2,179	2,681	3,055
13	0,694	1,350	1,771	2,160	2,650	3,012
14	0,692	1,345	1,761	2,145	2,624	2,977
15	0,691	1,341	1,753	2,131	2,602	2,947
16	0,690	1,337	1,746	2,120	2,583	2,921
17	0,689	1,333	1,740	2,110	2,567	2,898
18	0,688	1,330	1,734	2,101	2,552	2,878
19	0,688	1,328	1,729	2,093	2,539	2,861
20	0,687	1,325	1,725	2,086	2,528	2,845
21	0,686	1,323	1,721	2,080	2,518	2,831
22	0,686	1,321	1,717	2,074	2,508	2,819
23	0,685	1,319	1,714	2,069	2,500	2,807
24	0,685	1,318	1,711	2,064	2,492	2,797
25	0,684	1,316	1,708	2,060	2,485	2,787
26	0,684	1,315	1,706	2,056	2,479	2,779
27	0,684	1,314	1,703	2,052	2,473	2,771
28	0,683	1,313	1,701	2,048	2,467	2,763
29	0,683	1,311	1,669	2,045	2,462	2,756
30	0,683	1,310	1,697	2,042	2,457	2,750
40	0,681	1,303	1,684	2,021	2,423	2,704
60	0,679	1,296	1,671	2,000	2,390	2,660
120	0,677	1,289	1,658	1,980	2,358	2,617
∞	0,674	1,282	1,645	1,960	2,326	2,576

